

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Toni Peran

Zagreb, 2016. godina.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Željko Šitum, dipl. ing.

Student:

Toni Peran

Zagreb, 2016. godina.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se prof. dr. sc. Željku Šitumu na korisnim diskusijama i stručnoj pomoći.

Na kraju bih se zahvalio Bogu na obilnom blagoslovu, svojoj obitelji i djevojci koji su mi tijekom studiranja bili velika podrška, te im zahvaljujem na iskazanom povjerenju.

Toni Peran



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje
Datum 30.11.2016. Prilog
Klasa: 602-04/16-6/3
Ur.broj: 15-1703-16-378

DIPLOMSKI ZADATAK

Student: **TONI PERAN**

Mat. br.: 0035188020

Naslov rada na hrvatskom jeziku: **IDENTIFIKACIJA I REGULACIJA ELEKTROHIDRAULIČKOG SERVOSUSTAVA**

Naslov rada na engleskom jeziku: **IDENTIFICATION AND CONTROL OF AN ELECTRO-HYDRAULIC SERVOSYSTEM**

Opis zadatka:

Elektrohidraulički sustavi imaju široku primjenu u različitim industrijskim postrojenjima zbog mogućnosti ostvarenja velikih snaga s relativno malim uređajima i elementima, uz velike brzine odziva i visoke točnosti upravljanja. Dobro poznavanje dinamičkog ponašanja aktuatora u različitim radnim stanjima preduvjet je za ostvarenje naprednih metoda regulacije sustava. Međutim, hidraulički sustavi imaju izrazito nelinearnu dinamiku koja uključuje promjenljivost parametara sustava kao posljedicu fizikalnih značajki sustava, promjene opterećenja sustava i poremećaja tijekom procesa regulacije. Zbog toga je matematički model koji opisuje dinamiku hidrauličkog sustava ne samo nelinearan nego obuhvaća i veći broj nepoznatih parametara koje je potrebno identificirati u postupku sinteze regulatora.

U radu je potrebno:

- Objasniti teorijske osnove postupka identifikacije procesa u zadacima regulacije nelinearnih sustava s vremenski promjenljivim parametrima.
- Razraditi postupak identifikacije sustava za regulaciju položaja hidrauličkog cilindra upravljanog proporcionalnim ventilom. Postupak treba sadržavati izbor pobudnog signala, izbor vremena uzorkovanja, način prikupljanja podataka na temelju eksperimenta, izbor strukture modela sustava, procjenu parametara sustava (estimaciju procesa), te postupak provjere valjanosti modela (validaciju procesa).
- Načiniti sintezu regulatora na temelju dobivenog modela procesa.
- Razvijene regulacijske algoritme provjeriti eksperimentalno na laboratorijskom modelu elektrohidrauličkog servosustava.

Zadatak zadan:

29. rujna 2016.

Rok predaje rada:

1. prosinca 2016.

Predviđeni datum obrane:

7., 8. i 9. prosinca 2016.

Zadatak zadao:

Prof. dr. sc. Željko Šitum

Predsjednik Povjerenstva:

Prof. dr. sc. Franjo Cajner

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	V
POPIS OZNAKA	VI
SAŽETAK.....	VII
SUMMARY	VIII
1. UVOD.....	1
2. OPIS EKSPERIMENTALNOG SUSTAVA.....	2
2.1. Teorija i primjena.....	2
2.2. Dijelovi eksperimentalnog postava	4
2.2.1. Spremnik tekućine	5
2.2.2. Hidraulička crpka.....	6
2.2.3. Hidraulički cilindar	8
2.2.4. Proporcionalni razvodnik.....	10
2.2.5. Mjerni uređaj.....	12
2.2.6. Ostali dijelovi eksperimentalnog postava	13
3. IDENTIFIKACIJA PROCESA	14
3.1. Analiza elektrohidrauličkog sustava	14
3.1.1. Teorijska analiza	14
3.1.2. Eksperimentalna analiza	15
3.2. Metode eksperimentalne analize	17
3.3. Odabir pobudnih signala	19
3.4. Odabir vremena uzorkovanja	22
3.5. Prikupljanje ulazno-izlaznih podataka	24
3.5.1. Pseudo-random multi-level signal – PRMS.....	26
3.5.2. Pseudo-random binarni signal.....	27
3.5.3. Chirp signal.....	28
3.5.4. Sinusoida s tri frekvencije.....	29
3.5.5. Tendencija gibanja hidrauličkog cilindra u lijevu stranu.....	30
3.6. Estimacija i validacija procesa – System Identification Toolbox	33
3.6.1. Estimacija parametara i validacija – PRMS signal	37
3.6.2. Estimacija parametara i validacija – Chirp signal.....	42
3.6.3. Estimacija parametara i validacija – Sinusoida s tri frekvencije	45
3.6.4. Usporedba modela	46
4. SIMULACIJA PROCESA.....	52
4.1. Podešavanje parametara regulatora.....	52
4.2. Simulacija procesa	54
5. EKSPERIMENTALNI REZULTATI	57
6. ZAKLJUČAK.....	60
LITERATURA.....	61

PRILOZI.....	62
--------------	----

POPIS SLIKA

Slika 1.	Eksperimentalni elektrohidraulički postav	4
Slika 2.	Shema elektrohidrauličkog postava.....	5
Slika 3.	Spremnik tekućine i hidraulička crpka	6
Slika 4.	Hidraulička crpka unutar spremnika [10].....	7
Slika 5.	Hidraulički simboli pumpe	8
Slika 6.	Hidraulički cilindar eksperimentalnog sustava	9
Slika 7.	Hidraulički cilindar.....	9
Slika 8.	Primjeri označavanja cilindra	10
Slika 9.	4/3 proporcionalni razvodnik – „Bosch Rexroth“	10
Slika 10.	Funkcionalna shema i simbol proporcionalnog razvodnika.....	11
Slika 11.	Upravljanje u proporcionalnoj hidraulici [1].....	12
Slika 12.	Linearni FESTO enkoder	12
Slika 13.	Akvizijska kartica	13
Slika 14.	Blokovski dijagram sustava.....	13
Slika 15.	Pojednostavljenje matematičkog modela [6]	14
Slika 16.	Identifikacijski krug [6].....	17
Slika 17.	Primjer pseudo-random binarnog signala - PRBS [7].....	20
Slika 18.	Primjer pseudo-random multi-level signala - PRMS [7].....	21
Slika 19.	Primjer chirp signala [7].....	21
Slika 20.	Vrijeme uzorkovanja	22
Slika 21.	Grafičko sučelje System Identification Toolbox-a.....	24
Slika 22.	Blokovski dijagram prikupljanja podataka.....	25
Slika 23.	Odziv sustava na PRMS signal (veća frekvencija)	26
Slika 24.	Odziv sustava na PRMS signal (manja frekvencija)	27
Slika 25.	Odziv sustava na PRBS signal	28
Slika 26.	Odziv sustava na chirp signal	29
Slika 27.	Odziv sustava na sinusoidu s tri frekvencije	30
Slika 28.	Odziv s +10 V na razvodniku.....	31
Slika 29.	Odziv s -10 V na razvodniku.....	31
Slika 30.	Butterworthov filter signala brzine.....	32
Slika 31.	Filter brzine	32
Slika 32.	Unos podataka u System Identification Toolbox	33
Slika 33.	Odabir željene metode estimacije.....	34
Slika 34.	Opcije odabira načina estimacije.....	35
Slika 35.	Blokovska shema ARX modela [6].....	35
Slika 36.	Blokovska shema ARMAX modela [6]	36
Slika 37.	Blokovska shema OE modela [6].....	36
Slika 38.	Blokovska shema BJ modela [6]	36
Slika 39.	Ulazno-izlazni podaci PRMS signala za estimaciju - pozicija.....	37
Slika 40.	System Identification Toolbox – raspored podataka	38
Slika 41.	Mjereni i simulirani odziv sustava - PRMS (pozicija)	38
Slika 42.	Polovi i nule – PRMS	39
Slika 43.	Autokorelacijska i kroskorelacijska funkcija – PRMS.....	39
Slika 44.	Ulazno-izlazni podaci PRMS signala za estimaciju - brzina	41
Slika 45.	Mjereni i simulirani odziv sustava - PRMS (brzina).....	41
Slika 46.	Odziv na step funkciju – PRMS	42
Slika 47.	Ulazno-izlazni podaci chirp signala za estimaciju	42
Slika 48.	Mjereni i simulirani odziv sustava – Chirp signal.....	43

Slika 49.	Polovi i nule – Chirp signal (plavo – 3. red, crveno – 2. red sustava)	43
Slika 50.	Frekvencijski odziv	44
Slika 51.	Ulazno-izlazni podaci sinusoide s tri frekvencije za estimaciju.....	45
Slika 52.	Mjereni i simulirani odziv sustava - Sinusoida s tri frekvencije	45
Slika 53.	Polovi i nule - Sinusoida s tri frekvencije	46
Slika 54.	Usporedba modela na osnovi estimacije pomoću sinusoide s tri frekvencije	47
Slika 55.	Usporedba modela na osnovi estimacije pomoću PRMS signala	48
Slika 56.	Usporedba modela na osnovi estimacije pomoću PRBS signala	49
Slika 57.	Usporedba modela na osnovi estimacije pomoću chirp signala.....	49
Slika 58.	OE model dinamike sustava	50
Slika 59.	Odziv procesa na skokovitu pobudu - eksperiment u otvorenom krugu [10]	52
Slika 60.	Određivanje kritičnog pojačanja regulatora	54
Slika 61.	Regulacijski krug – simulacija	54
Slika 62.	Podsustav PID	55
Slika 63.	Odziv regulacijskog kruga na referentni signal – PID regulator	55
Slika 64.	Odziv regulacijskog kruga na referentni signal – PD regulator	56
Slika 65.	Eksperimentalni regulacijski krug	57
Slika 66.	Podsustav PD regulatora eksperimentalnog regulacijskog kruga	58
Slika 67.	Eksperimentalni rezultati	58
Slika 68.	Usporedba simulacije i eksperimenta.....	59

POPIS TABLICA

Tablica 1. Takahashijeve preporuke [10]	53
---	----

POPIS OZNAKA

Oznaka	Jedinica	Opis
Q	m^3/s	Volumenski protok
v_f	m/s	Srednja prosječna brzina fluida
S	m^2	Površina poprečnog presjeka cijevi
ρ	kg/m^3	Gustoća
α	-	Koeficijent ispravka kinetičke energije
P	W	Snaga
M	Nm	Moment
ω	s^{-1}	Kutna brzina
η_P	-	Ukupni stupanj korisnog djelovanja pumpe
η_M	-	Ukupni stupanj korisnog djelovanja motora
V	m^3	Radni volumen
n	-	Broj okretaja stroja
L	m	Duljina cjevovoda
D	m	Promjer cjevovoda
λ	-	Koeficijent viskoznog trenja
T_s	s	Vrijeme uzorkovanja
u	V	Napon upravljačkog signala
x	mm	Pozicija hidrauličkog cilindra
v	mm/s	Brzina hidrauličkog cilindra
K_P	-	Statičko pojačanje procesa
τ	s	Kašnjenje procesa
T_P	s	Nadomjesna vremenska konstanta
K_u	-	Kritično pojačanje
T_u	s	Period oscilacija

SAŽETAK

Tema ovog diplomskog rada je identifikacija elektrohidrauličkog sustava pomoću *Matlabovog* programskog alata *System Identification Toolbox*. Cilj ovoga procesa je dobivanje matematičkog modela koji opisuje dinamiku eksperimentalnog elektrohidrauličkog postava i omogućavanje sinteze regulatora pozicije hidrauličkog cilindra.

Kako bi se to postiglo, na ulaz eksperimentalnog sustava se dovode pobudni signali različitog karaktera i snima se odziv sustava. Ulaz sustava predstavlja napon (-10 V do +10 V) na hidrauličkom razvodniku, a izlaz sustava je pozicija hidrauličkog cilindra koja se mjeri pomoću linearnog enkodera. Da bi se dobio što bolji model i prikazalo što vjernije praćenje referentnog signala potrebno je odabrati dobar pobudni signal. Nakon prikupljanja ulazno-izlaznih podataka, na osnovi njih, pristupa se estimaciji parametara modela pomoću različitih metoda estimacije. Nakon estimacije, proveden je proces validacije modela gdje se prikazuje kvaliteta odziva različitih modela i uspoređuju se s mjerenim odzivom i međusobno.

Kada se dobije zadovoljavajuće ponašanje modela, njegova prijenosna funkcija predstavlja stvarni proces u regulacijskom krugu i provodi se sinteza regulatora. Projektirani regulator je prvo provjeren na računalnoj simulaciji u *Simulinku*, a poslje toga je primijenjen na eksperimentalni sustav.

Ključne riječi: Elektrohidraulički sustav, identifikacija procesa, estimacija parametara modela, validacija, sinteza regulatora.

SUMMARY

The subject of this thesis is identification of an electro-hydraulic servosystem with *Matlab* tool *System Identification Toolbox*. Objective of this process is to get a mathematical model which describes dynamics of experimental electro-hydraulic system and to make possible controller synthesis for position of hydraulic cylinder.

To achieve that, the various kinds of signals are applied on the input of experimental system and the output is recorded. Input of the system is voltage (from -10 V to +10 V) on hydraulic distributor, and the output is position of the hydraulic cylinder which is measured with linear encoder. To get the better model and to present better tracking of reference signal it is necessary to choose the right excitation signal. After recording of input-output data, parameter estimation follows with different estimation methods. After estimation, the process of validation is carried out where the quality of different models is shown and their comparison with measured response.

When there is satisfying behaviour of the model, its transfer function represents the real process in control circuit and then the controller synthesis is carried out. First the designed controller is tested on computer simulation in *Simulink* and then applied on experimental system.

Key words: Electro-hydraulic system, identification of process, parameter estimation of model, validation, controller synthesis.

1. UVOD

Elektrohidraulički upravljački sustavi se široko koriste u industriji zbog njihovog omjera veličine i snage, krutosti i male pozicijske pogreške. Međutim, dinamika hidrauličkih sustava je izrazito nelinearna. Na nelinearnost utječe saturacija upravljačkog ulaza, trenje, preklapanje ventila, nelinearna karakteristika zavisnosti tlaka i protoka i promjene smjera toka tekućine. Upravljanje takvim sustavima je poprilično razvijeno, ali modeliranje i identifikacija takvih upravljačkih sustava predstavlja važan i težak problem u stvarnim primjenama.

Linearni modeli elektrohidrauličkih sustava su jednostavni i široko se koriste, ali se u njima pretpostavlja da se aktuator uvijek nalazi u određenoj radnoj točki što nije slučaj u stvarnosti gdje su prisutne mnoge nelinearnosti. Aktuator može koristiti proporcionalni ili servo ventil za pogon. Da bi se postigle što bolje performanse elektrohidrauličkog aktuatora, mora postojati dobar regulator sustava. Kako regulator zahtjeva matematički model sustava kojeg regulira, mora se provest identifikacija sustava da bi se postigli najbolji rezultati odziva. Identifikacija sustava će otkriti dinamičko ponašanje eksperimentalnog postava na različite režime rada da bi se mogla provesti kvalitetna sinteza regulatora.

Nekada jednostavno nije moguće teorijski odrediti model eksperimentalnog sustava i ne smije se eksperimentirati s pretpostavkama regulatora, zbog sigurnosti i osjetljivosti procesa ili drugih razloga. U tom slučaju, na eksperimentalni postav se primjene određeni pobudni signali i snima se njegov odziv kako bi se dobila ulazno-izlazna karakteristika pomoću koje provodimo estimaciju parametara modela. Koje metode estimacije se koriste i koji ulazni signali se preporučuju prikazano je u nastavku rada.

2. OPIS EKSPERIMENTALNOG SUSTAVA

2.1. Teorija i primjena

Elektrohidraulički sustavi su hidraulički sustavi kojima se upravlja pomoću električnih signala. Dakle sastoje se od dva dijela, a to su:

- hidraulički izvršni član
- električni upravljački član

Hidraulika predstavlja energetska član, zbog svojih izuzetnih prednosti nad ostalim sustavima, pogotovo kada su u pitanju velike snage. U takvim sustavima se računa na velike sile i opterećenja što su karakteristike hidrauličkih uređaja.

Svakim takvim moćnim energetska dijelom u industriji se upravlja malim informacijskim signalima koji su električne naravi. U tome je danas prednost razvoja računalne tehnologije da imamo mogućnost s malim signalima u računalu upravljati energetska dijelovima koji nam se čine nezamislivi.

Kada su se elektrohidraulički sustavi počeli pojavljivati u industriji, njihova primjena na početku je bila za one sustave koji su zahtjevali veoma visoke snage. Dok su i danas elektrohidraulički servosustavi još uvijek korišteni za te primjene, počinje se sve više povećavati njihova prisutnost u različitim granama industrije. Tehnologija pogona sa zatvorenim petljom brzo postaje norma u automatizaciji proizvodnje gdje se zahtjeva velika preciznost, brze operacije i jednostavno podešavanje. Postoje i očekivanja da će ubrzo i cijena takvih primjena biti u prihvatljivim granicama.

Elektrohidraulički sustavi razvijeni su za upravljanje objektima velikih snaga, kod kojih se zahtjeva velika točnost pozicioniranja i velika brzina odziva. Takvi sustavi dijele se po kategoriji razvodnog uređaja hidraulike pa onda imamo sljedeće tri kategorije:

- klasična hidraulika
 - razvodni uređaji su obično ventili sa on – off (dvopoložajnim) elektromagnetima
- proporcionalna hidraulika
 - razvodni uređaji su proporcionalni ventili
- hidraulički servosustavi
 - razvodni uređaji su servo ventili

Hidraulika je dio mehanike fluida koji se bavi proučavanjem stanja ravnoteže i strujanja realne tekućine, ponajprije vode, kroz cijevi, kanale i otvore, te pojava koje nastaju kada takva tekućina struji oko nekoga tijela uronjenoga u nju. Hidraulika je znanstvena i tehnička disciplina koja proučava oblike i zakone mehaničkog gibanja i relativnog mirovanja tekućina. Razvojem proizvodnje i tehnike širila su se i područja proučavanja i primjene. Danas je raspon primjene hidraulike toliko širok da je teško naći neko područje tehnike u kojem se ne bi na neki način

koristili njeni zakoni. Najšira područja primjene su vodogradnja ili hidrotehnika, opskrba vodom i kanalizacija, hidroenergetika, vodeni prijevoz (transport), alatni strojevi, poljoprivredni i građevinarski strojevi, cestovna i tračnička vozila, brodogradnja, avionska industrija, industrijska robotika, itd.

U odnosu na druge tehnologije hidraulika ima niz prednosti koje su ubrzale porast njezine primjene u industriji.

Neke od tih prednosti su sljedeće:

- prijenos velikih sila s relativno malim uređajima i elementima
- jednostavna pretvorba hidrauličke energije u mehaničku
- laka zaštita od preopterećenja
- jednostavno podešavanje brzine, okretnog momenta, sile, itd.
- gustoća snage
- jednostavna realizacija linearnog gibanja
- dobre mogućnosti upravljanja
- dobra dinamika (male sile inercije)
- dobro podmazivanje i odvođenje topline pomoću fluida.

Uz sve te prednosti hidraulički sustavi nose sa sobom i neke nepoželjne posljedice primjene takve tehnologije.

Neki od glavnih nedostataka su sljedeći:

- slabija korisnost (zbog trenja i gubitaka curenjem)
- povećana potreba za održavanjem (zbog nečistoće i trošenja komponenti)
- osjetljivost s ekološkog gledišta (buka, curenje, opasnost požara)
- nedovoljno poznavanje
- potreba za povratnim vodovima
- skupi uređaji i elementi.


2.2. Dijelovi eksperimentalnog postava

Za upravljanje elektrohidrauličkih sustava koriste se električni signali i podsustavi koji određuju ponašanje izvršnog člana tj. hidrauličkog klipa i cilindra koji predstavljaju aktuator u sustavu. Pogon sustava predstavlja zupčasta hidraulička crpka koja 'gura' fluid kroz sustav. Na sljedećoj slici (*Slika 1.*) možemo vidjeti sve elemente eksperimentalnog hidrauličkog postava:



Slika 1. Eksperimentalni elektrohidraulički postav

- | | |
|----------------------------|------------------------------------|
| 1 – Spremnik tekućine | 7 – Manometar |
| 2 – Elektromotor | 8 – Upravljačka kutija |
| 3 – Hidraulički cilindar | 9 – Postolje |
| 4 – Proporcionalni ventil | 10 – Spojka |
| 5 – Hidraulička crijeva | 11 – Kabel za spajanje s računalom |
| 6 – Hidraulički akumulator | 12 – Sklopka za uklj./isklj. crpke |



Slika 2. Shema elektrohidrauličkog postava

2.2.1. Spremnik tekućine

U spremniku tekućine (Slika 3.) na elektrohidrauličkom sustavu nalazi se ulje za opskrbu cijelog sustava. Hidraulički fluid služi za prijenos energije od hidrauličke pumpe do hidrauličkog

aktuatora, u ovom slučaju hidrauličkog cilindra. Izbor odgovarajuće tekućine ima bitan utjecaj na ispravan rad, trajnost, pouzdanost i ekonomičnost hidrauličkog pogona.



Slika 3. Spremnik tekućine i hidraulička crpka

Vrste fluida koje se koriste u hidrauličkim pogonima su voda i vodene emulzije, mineralna ulja, sintetičke tekućine i tekući metali i legure.


Zadaci hidrauličke tekućine

- prijenos energije – glavni zadatak
- hlađenje
- podmazivanje
- zaštita od korozije
- odnošenje nečistoća.

2.2.2. Hidraulička crpka

Hidraulička crpka je pogonski stroj i sastavni dio hidrauličkog pogona i njoj pripada uloga energetskog člana hidrauličkog sustava. Crpki je izvana dovedena mehanička energija i ona je

pretvara u energiju radnog fluida. U eksperimentalnom postavu je instalirana zupčasta hidraulička pumpa (Slika 4.) proizvođača Vivoil, maksimalnog protoka $Q = 4 \text{ l/min.}$ i tlaka $p = 250 \text{ bar.}$ Crpku pogoni jednofazni kavezni asinkroni elektromotor proizvođača Končar, snage $P = 1,1 \text{ kW}$ i broja okretaja $n = 1380 \text{ o/min.}$ Na slici 3. možemo vidjeti da je elektromotor smješten iznad spremnika i povezan je pomoću spojke sa crpkom koja je smještena unutar spremnika fluida.



Slika 4. Hidraulička crpka unutar spremnika [10]

Zupčasta hidraulička pumpa je volumenska pumpa i predaje snagu fluida tako da zubi zupčanika ostvaruju silu pritiska na fluid. Primjenjuju se za relativno velike protoke i male visine dobave.

U najvećem broju slučajeva ulje se može smatrati nestlačivim, tj. gustoća ulja se smatra konstantnom ($\rho = \text{const.}$). U slučaju kada se strujanje može smatrati stacionarnim, zakoni održanja mase i energije za strujanje ulja u cjevovodnim mrežama hidrauličkih sustava poprimaju sljedeće oblike:

Jednadžba kontinuiteta (zakon održanja mase):

Volumenski protok ulja u cijevi je konstantan

$$Q = v_f S = \text{const.}, \quad (1)$$

i iznosi 4 l/min pri čemu v označava srednju protočnu brzinu ulja, a S je poprečni presjek cijevi.

U cjevovodnim mrežama suma svih volumenskih protoka koji ulaze u čvor cjevovoda (račvu) mora biti jednaka sumi svih protoka koji iz čvora izlaze:

$$\Sigma Q_{ul} = \Sigma Q_{iz}, \quad (2)$$

Pumpa i motor

Snaga stroja (motora, pumpe) na spojci jednaka je umnošku momenta na spojci (vratilu) i kutne brzine vrtnje ($P = M \omega$).


Snaga pumpe P_P jednaka je:

$$P_P = \frac{Q \Delta p_P}{\eta_P}, \quad (3)$$

pri čemu je η_P ukupni stupanj korisnog djelovanja pumpe, Δp_P je prirast totalnog tlaka u pumpi, a snaga motora:

$$P_M = \eta_M Q \Delta p_M, \quad (4)$$


pri čemu je η_M ukupni stupanj korisnog djelovanja motora.



Slika 5. Hidraulički simboli pumpe

2.2.3. Hidraulički cilindar


Hidraulički cilindar je translacijski izvršni član hidrauličkog sustava jer je to element koji pretvara hidrauličku energiju u mehaničku. Preko tog elementa pojačani i vremenski oblikovani signal razlike u regulaciji djeluje na proces. U hidraulici se takvi elementi zovu hidraulički aktuatori ili motori tj. uređaji koji pretvaraju energiju fluida u neku vrstu gibanja. U ovom slučaju se ta energija pretvara u translacijsko gibanje radnog klipa. U eksperimentalnom postavu hidraulički cilindar možemo vidjeti na sljedećoj slici (*Slika 6.*).



Slika 6. Hidraulički cilindar eksperimentalnog sustava


Kako cilindar proizvodi linearna gibanja u literaturi se često naziva i hidraulički linearni motor. Pogonski cilindar ovog eksperimentalnog sustava (*Slika 6.*) je dvoradni cilindar promjera klipa 50 mm, s klipnjačom promjera 36 mm te maksimalnog hoda 300 mm. Kod dvoradnih cilindara može se upravljati i lijevom i desnom komorom pa imamo sposobnost gibanja u obje strane.

Na sljedećoj slici može se vidjeti presjek jednog hidrauličkog cilindra koji svoju energiju pretvara u translacijsko gibanje.




Slika 7. Hidraulički cilindar

Snagu dobivaju od fluida pod tlakom, obično ulja. Sastoje se od cilindra i klipa koji se giba unutar cilindra. Kako se neki primjeri cilindara označuju na hidrauličkim shemama možemo vidjeti na sljedeći način:



Jednoradni cilindar




Dvoradni cilindar

Slika 8. Primjeri označavanja cilindara

2.2.4. Proporcionalni razvodnik

Glavni upravljački član elektrohidrauličkog sustava je proporcionalni razvodnik. Razvodnik ili razvodni ventil je vrsta hidrauličkog ventila koji usmjerava tok hidrauličkog fluida u hidrauličkom pogonu propuštanjem, zatvaranjem ili promjenom smjera toka. To je uređaj za upravljanje ili regulaciju pokretanja, zaustavljanja, te tlaka i protoka fluida pod tlakom dobavljenog crpkom ili pohranjenog u akumulatoru (*DIN/ISO 1219*). Proporcionalni razvodnik je kontinuirano pokretani razvodnik koji između dva krajnja položaja kontinuirano poprima neki položaj uz odgovarajuće prigušno djelovanje.




Slika 9. 4/3 proporcionalni razvodnik – „Bosch Rexroth“

Na prethodnoj slici (Slika 9.) možemo vidjeti instalirani proporcionalni razvodnik na eksperimentalnom sustavu. Elektrohidraulički proporcionalni razvodnik predstavlja najvažniju komponentu u elektrohidrauličkom servosustavu. To je upravljačka komponenta koja nam

omogućuje spojiti tehnike elektroničkog upravljanja s razmatranim objektom upravljanja. Proporcionalni razvodnik sadrži elektroničko pojačalo i proporcionalni magnet sa naponskom karakteristikom hoda. On upravlja protokom Q kojeg daje pumpa pod tlakom p_s i na taj način djeluje na hidraulički sustav.


Na sljedećoj slici (Slika 10.) možemo vidjeti funkcionalnu shemu rada proporcionalnog razvodnika:



Slika 10. Funkcionalna shema i simbol proporcionalnog razvodnika

Proporcionalna tehnika u hidraulici je sve više zastupljena u automatizaciji. Klasična (*on-off*) hidraulika se ne može koristiti za sve aplikacije, posebno kada se traži velika točnost upravljanja određenog procesa. Kada se kontrolira pozicija, tlak, brzina, određeni kut onda se neminovno

mora primijeniti proporcionalna tehnika upravljnja hidrauličnim uređajima. U proporcionalnoj hidraulici se primjenjuju proporcionalni razvodnici koji imaju prednost ispred klasičnih razvodnika. Dolazi do objedinjavanja prednosti hidraulike s prednostima koje omogućuje elektronika, a to su fleksibilnost, preciznost, prijenos i obrada signala.



Slika 11. Upravljanje u proporcionalnoj hidraulici [1]

2.2.5. Mjerni uređaj

Za mjerenje pozicije hidrauličkog cilindra koristi se linearni enkoder tvrtke „FESTO“. Izveden je u obliku malog cilindra s pomičnom klipnjačom koja je pričvršćena za klipnjaču hidrauličkog cilindra pa se gibanjem hidrauličkog cilindra ostvaruje i gibanje linearnog enkodera. Enkoder ima hod od 300 mm, što je ekvivalentno hodu klipa u hidrauličkom cilindru. Ima rezoluciju 0,01 mm, a na izlazu daje naponski signal u rasponu od 0 do 10 V. Maksimalna brzina kretanja enkodera iznosi $v = 5 \text{ m/s}$, a maksimalno ubrzanje $a = 200 \text{ m/s}^2$.



Slika 12. Linearni FESTO enkoder

2.2.6. Ostali dijelovi eksperimentalnog postava

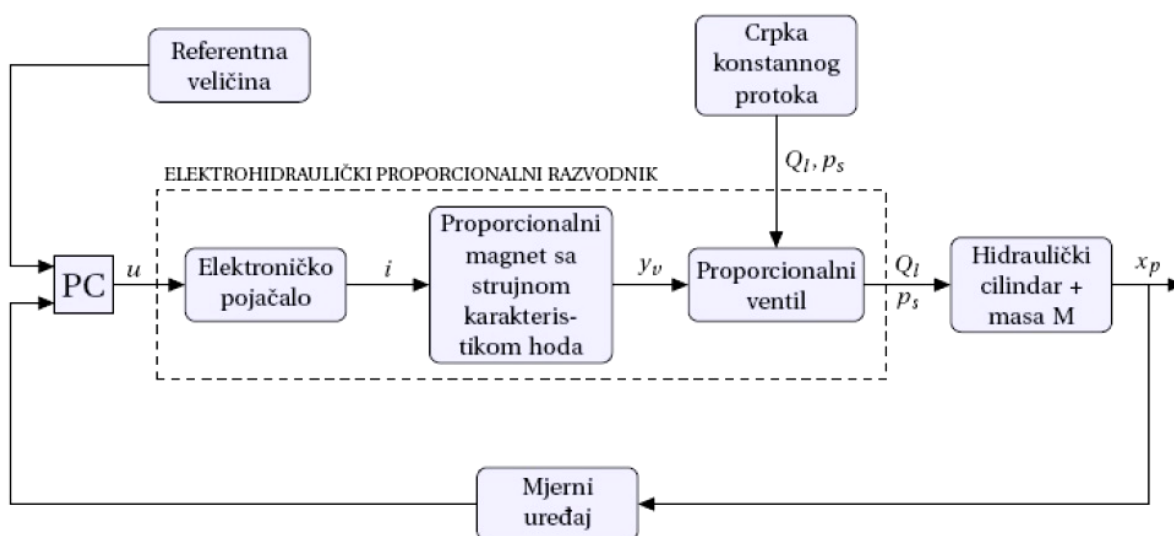
Osim onih 'glavnih' dijelova eksperimentalnog sustava koji su prethodno opisani, eksperimentalni postav se sastoji i od drugih bitnih dijelova za funkcioniranje sustava. Neki od tih elemenata su crijeva, prigušni elementi, mjerni instrumenti, ventili za upravljanje tlakom, ventili za upravljanje protokom, nepovratni ventili i ostali.

Računalo komunicira s eksperimentalnim postavom preko akvizicijske kartice tvrtke „National Instruments“ koja je prikazana na sljedećoj slici:



Slika 13. Akvizicijska kartica

Blokovski dijagram prikazuje tijek signala (u smjeru strelice) kroz sustav te međusobnu vezu komponenata koje grade sustav.



Slika 14. Blokovski dijagram sustava

3. IDENTIFIKACIJA PROCESA

3.1. Analiza elektrohidrauličkog sustava

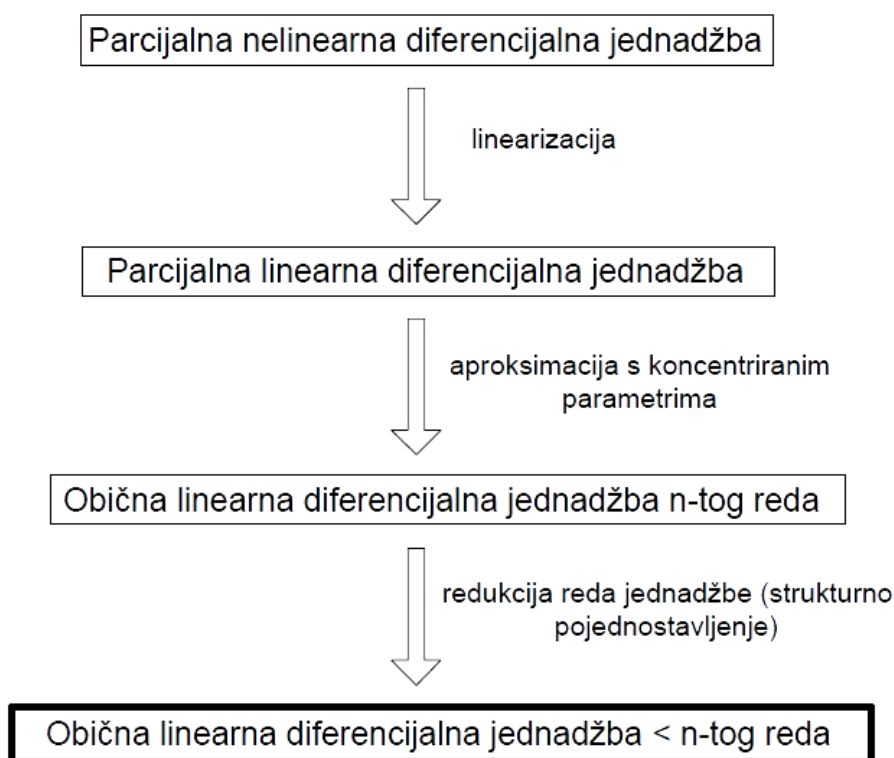
U identifikaciji sustava cilj nam je doći do matematičkog opisa vremenskog ponašanja razmatranog sustava. Konkretno, u ovom slučaju cilj nam je doći do matematičkog opisa ponašanja elektrohidrauličkog sustava. Do ponašanja određenog sustava možemo doći na više načina analize tog istog sustava i njegovih procesa i signala.

Analizu procesa možemo podijeliti na:

- teorijsku analizu (modeliranje)
- eksperimentalnu analizu (identifikacija).

3.1.1. Teorijska analiza

Za teorijsku analizu procesa potrebno je znati zakonitosti rada elemenata procesa i njihova međudjelovanja. Početni koraci za izvođenje ove metode su postavljanje jednačbi ravnoteže energije, mase itd. i postavljanje fizikalno-kemijskih jednačbi stanja. Za ireverzibilne procese postavljaju se također i fenomenološke jednačbe. Nakon toga dolazi i eventualno postavljanje jednačbi ravnoteže entropija ako se događa više ireverzibilnih procesa.



Slika 15. Pojednostavljenje matematičkog modela [6]

Rezultat ove metode je sustav običnih i parcijalnih diferencijalnih jednačbi. Međutim, te jednačbe su obično dosta pojednostavljene i ne opisuju egzaktno ponašanje sustava, ali opet dovoljno dobro za primjenu kod upravljanja ili regulacije takvih sustava. Na prethodnoj slici možemo vidjeti proces pojednostavljenja matematičkog modela procesa dobivenog teorijskom analizom.

Prednosti:

- u fazi planiranja i projektiranja procesa i sustava automatizacije realni proces ne mora postojati
- dobivena rješenja općenito su valjana za slične klase procesa (za druge dimenzije varijabli i parametara)
- dobar uvid u unutarnje odnose procesa (ovisnosti i odnosi među varijablama stanja)

Nedostatci:

- složeni matematički modeli često su neprikladni za daljnje primjene (npr. simulacija sustava upravljanja i projektiranje regulatora)
- nesigurnost određivanja parametara procesa i vanjskih poremećajnih djelovanja.

U teorijskom modeliranju struktura modela je posljedica prirodnih zakona što znači da moramo poznavati opis ponašanja unutarnjih akumulatora stanja i ulazno-izlaznog ponašanja. Parametri modela su dati kao funkcije procesnih veličina i model je valjan za velik dio tipova procesa pri različitim pogonskim stanjima. Mnoge procesne veličine su vrlo malo ili nedovoljno poznate pa nam je to prednost. Sama analiza zahtjeva dosta vremena za razvoj jer su nam bitna unutarnja stanja procesa koja moramo saznati iz matematičkog opisa.

3.1.2. Eksperimentalna analiza

Identifikacija sustava je postupak izgradnje matematičkog modela na temelju eksperimentalno snimljenih podataka sustava. U eksperimentalnoj analizi procesa matematički model dobijemo uz upotrebu mjerenih ulaznih i izlaznih signala. Za ulazne signale upotrebljavamo točno određene ispitne signale u ovisnosti o sustavu. Postoji više identifikacijskih postupaka koje primjenjujemo za parametarske ili neparametarske modele, a kao rezultat dobijemo eksperimentalni model sustava ili procesa.

Pri identifikaciji procesa uvijek se polazi od a priori znanja o procesu dobivenih:

- teorijskom analizom

- prethodnim mjerenjima

Prednosti

- nisu potrebna detaljna specijalistička znanja istraživanog procesa
- dobivaju se jednostavniji matematički modeli koji zadovoljavajuće dobro opisuju proces

Nedostatci:

- mora postojati istraživani proces
- dobiveni rezultati ograničeno su primjenjivi za slične procese


Analiza procesa općenito je iterativni postupak kombiniran teorijskom i eksperimentalnom analizom. Hoćemo li primijeniti parametarske ili neparametarske postupke identifikacije ovisi o tome je li struktura modela poznata ili nije. Kao rezultat ćemo u svakom slučaju dobiti eksperimentalni model.

Ako se obavlja teorijska analiza, tada se eksperimentalna analiza koristi za provjeru točnosti teorijskog modela ili za određivanje parametara. Može se također usporedbom dobivenih modela zaključiti, na temelju vrste i veličine međusobnog odstupanja, što je potrebno korigirati u teoretskom ili eksperimentalnom modelu.

U našem slučaju eksperimentalnom analizom procesa dobiveni matematički model može se koristiti za sljedeće svrhe:

- proučavanje elektrohidrauličkog procesa
- provjera teorijskog modela (ako ga poznajemo)
- projektiranje (sinteza) sustava upravljanja
- optimiranje vladanja procesa u stacionarnim i dinamičkim režimima rada
- adaptivno upravljanje
- dijagnostika procesa
- estimacija nemjerljivih varijabli procesa.

Razvoj procesnih računala za regulaciju, nadzor i optimiranje procesa značajno je pridonio eksperimentalnoj analizi.



Slika 16. Identifikacijski krug [6]

Zadaća identifikacije jest odrediti matematički model procesa (P) na temelju mjerenih signala $u_m(t)$ i $y_m(t)$, i eventualno drugih mjerenih signala.

Pri identifikaciji većine procesa moraju se imati u vidu sljedeće činjenice:

- Raspoloživo vrijeme T_M za eksperiment je ograničeno iz procesnih razloga zbog vremenske varijantnosti svojstava procesa:

$$T_M \leq T_{M \max} \quad (5)$$

Pri pobudi procesa kontinuiranim ispitnim signalom i uz mjerenja u diskretnom vremenu nužno je poštivati Shannonov teorem.

- Promjenu ispitnog signala potrebno je uvijek ograničiti na maksimalno dozvoljeni iznos što je uvjetovano procesnim razlozima ili održanjem linearnih svojstava procesa:

$$u_0 = u(t)_{\max} - u(t)_{\min} \leq u_{0\max} \quad (6)$$

- Promjenu izlaznog signala potrebno je imati ograničenu zbog istih prethodnih razloga:

$$y_0 = y(t)_{\max} - y(t)_{\min} \leq y_{0\max} \quad (7)$$

3.2. Metode eksperimentalne analize

Metode postupaka identifikacije možemo podijeliti na parametarske i neparametarske metode prema matematičkom modelu. Parametarski modeli predstavljaju se jednažbama, koje eksplicitno sadrže parametre (npr. diferencijalne jednažbe, prijenosne funkcije).

Neparametarski modeli prikazuju ovisnost ulazne i izlazne veličine procesa u obliku tablica vrijednosti ili krivulja (npr. težinske funkcije, prijelazne funkcije u tabličnom ili grafičkom obliku). Neparametarski modeli sadrže parametre implicitno.

Osnovne metode tj. postupci identifikacije parametara linearnih procesa su:

- Fourierova analiza
- Korelacijska analiza
- Spektralna analiza
- Referentni model
- Procjena parametara

Fourierova analiza

Fourierova analiza koristi se uglavnom za linearne procese s kontinuiranim signalima za određivanje frekvencijske karakteristike procesa. Karakteristično je za ovu metodu:

- jednostavna obrada rezultata računalom
- preporuča se za procese s relativno malim odnosom (signal smetnje)/(ispitni signal)

Korelacijska analiza

Korelacijska analiza primjenjuje se u vremenskom području i prikladna je za linearne procese, kako s kontinuiranim, tako i s diskretnim signalima. Za ulazne ispitne signale koriste se stohastički ili periodički signali. Kao rezultat korelacijske analize dobiva se korelacijska funkcija, odnosno u posebnom slučaju težinska funkcija. Karakteristično je za ovu metodu:

- jednostavna obrada rezultata računalom
- prikladna je za procese s relativno velikim odnosom (signal smetnje)/(ispitni signal)

Spektralna analiza

Spektralna analiza primjenjuje se pod istim uvjetima kao i korelacijska analiza. Obrada se obavlja u frekvencijskom području. Izračunava se spektralna gustoća signala.

Fourierovom analizom, korelacijskom analizom i spektralnom analizom dobiju se neparametarski modeli procesa. Kao a priori informacija mora biti poznato samo da se proces može linearizirati. Ne mora se pretpostaviti određena struktura modela. Stoga su ove

neparametarske metode prikladne, kako za procese s koncentriranim parametrima, tako i za procese s raspodijeljenim parametrima s proizvoljno složenom strukturom.

Referentni model

Metoda zasnovana na referentnom modelu prikladna je za matematičke modele s kontinuiranim signalima. Uz pretpostavljenu strukturu modela dobiju se parametri diferencijalnih jednadžbi ili jednadžbi diferencija.

Pri tome je potrebno osigurati da ulazni signali pobude sve interesantne karakteristične frekvencije procesa.

Procjena parametara

Metode procjene parametara matematičkih modela procesa prikladne su, kako za diskretne, tako i za kontinuirane signale. Ispitni signali procesa mogu općenito imati proizvoljan oblik, ali takav da trajno pobuđuju interesantne karakteristične frekvencije procesa. Kao signal pogreške između matematičkog modela i procesa koristi se poopćena pogreška (i izlazna pogreška). Algoritmi procjene parametara mogu biti nerekurzivni i rekurzivni. Postupak procjene parametara, kojim se dobije diskretni parametarski model, posebno je prikladan za sintezu algoritama upravljanja (npr. adaptivno upravljanje) ili simulaciju procesa. Metode zasnovane na referentnom modelu i na procjeni parametara daju parametarske modele. Pri određivanju parametara ovih modela mora se pretpostaviti određena struktura modela. [6]

Osnovni neparametarski postupci identifikacije su:

- Identifikacija pomoću Fourierove analize
- Identifikacija pomoću korelacijske analize


3.3. Odabir pobudnih signala

Da bi sustav bio dobro identificiran važno je definirati tip signala koji će se koristiti tijekom eksperimentalnog snimanja ulazno-izlaznog ponašanja. Očito je da u pripremi identifikacije možemo puno toga napraviti samo odabirom razumnih i dobrih signala.

U području identifikacije linearnih sustava široko je korišten *pseudo-random binarni signal* (PRBS) koji sadrži samo dvije razine amplitude (vidi *Slika 17.*). Za nelinearne sustave


korištenjem takvog signala može se izgubiti dosta informacija o sustavu. Za nelinearne sustave je važno da su sve zanimljive amplitude i frekvencije i sve njihove kombinacije prisutne u uzbudnom signalu. Za njih se preporučuju sljedeći uzbudni signali:

- neovisne sekvence sa Gaussovom ili uniformnom raspodijeljenošću
- pseudo-random signali s više razina (PRMS, engl. pseudo-random multilevel signals) gdje se razina mijenja sa svakim n-tim uzorkovanjem ili slučajno
- chirp signali (multi-sinusoidalni)




Slika 17. Primjer pseudo-random binarnog signala - PRBS [7]

Za razliku od *pseudo-random binarnog signala* (PRBS) koji ima samo dvije razine amplitude, dodavajući dodatne razine amplitude dobijemo *pseudo-random multi-level signal* (PRMS) (vidi *Slika 18.*). Praktična iskustva su pokazala da će najbolja performansa modela biti postignuta ako se vrijeme mijenjanja (ili vrijeme zadržavanja) razine amplitude odredi kompromisom između dvije stvari. S jedne strane, trajanje mora biti dovoljno dugo da bi se ostvario efekt na izlazu, a s druge strane predugo vrijeme neće dati više informacije o dinamici sustava. Ključno je u ovom slučaju odabrati vrijeme koje je negdje blizu vremena smirivanja sustava na step pobudu.



Slika 18. Primjer pseudo-random multi-level signala - PRMS [7]

Chirp signal je sinusoidalni signal sa stupnjevitim povećanjem vlastite frekvencije, počevši od $\omega_{\text{početak}}$ i završavajući na frekvenciji ω_{kraj} u određenom vremenu. Na *Slici 19.* prikazan je primjer chirp signala.




Slika 19. Primjer chirp signala [7]

Kada se chirp signal primjenjuje na nelinearne sustave, mora se ponoviti proces identifikacije i snimanja karakteristika nekoliko puta jer se mora provjeriti ponašanje za različite kombinacije vrijednosti offseta signala i amplitude. Iskustvo u identifikaciji, prema Jelali-ju [7], je pokazalo da su PRMS signali puno bolji kao izbor pobudnog signala. Jednostavno vode do boljih modela nego kada koristimo chirp signale.

3.4. Odabir vremena uzorkovanja

Uzorkovanje je proces uzimanja uzoraka kontinuiranog signala i redukcije u diskretni signal. Vrijeme uzorkovanja T je vrijeme između uzimanja dvaju uzoraka od originalnog signala kao što možemo vidjeti na sljedećoj slici:



Slika 20. Vrijeme uzorkovanja

Odabir pravoga vremena uzorkovanja za identifikaciju sustava je rezultat kompromisa mnogo faktora:

- Ako je interval ukupnog vremena za identifikaciju fiksiran, onda je korisno odabrati kratko vrijeme uzorkovanja, zbog mogućnosti pokrića više točaka (i/ili kombinacija amplituda-frekvencija). Vrijeme uzorkovanja ne bi trebalo biti prekratko uspoređujući sa dinamikom sustava kako bi se izbjegli ozbiljni numerički problemi u estimaciji parametara zbog malih promjena u svakom sljedećem očitavanju.
- Ako je ukupni broj podataka fiksiran ili ograničen, onda odabir vremena uzorkovanja mora biti kompromis: ako je prevelik, tada će podaci sadržavati jako malo informacija

o visoko-frekventnoj dinamici; ako je premalo, onda će poremećaji imati veliki utjecaj i podaci će sadržavati malo informacija o nisko-frekventnoj dinamici.

Uvijek možemo odabrati vrijeme uzorkovanja da bude 10-20% od vremena smirivanja sustava na step pobudu. Puno gore može biti uzimanje prevelikoga vremena uzorkovanja nego uzimanje premaloga vremena [16].

Neke smjernice postoje za linearne sustave; upotrebom karakterističnih vrijednosti step odziva sustava, ponuđena su nam vremena uzorkovanja sljedećih intervala:

Prema Unbehauen-u iz 1995., parametarski modeli:

$$\frac{T_0}{T_{63}} = \frac{1}{10} \dots \frac{1}{6} \quad (8)$$

prema Isermann-u iz 1992:

$$\frac{T_0}{T_{95}} = \frac{1}{15} \dots \frac{1}{5} \quad (9)$$

prema Isermann-u iz 1987., digitalno upravljanje:

$$\frac{T_0}{T_{95}} = \frac{1}{15} \dots \frac{1}{4} \quad (10)$$

prema Wernstedt-u iz 1989., diskretni modeli,

$$\frac{T_0}{T_{63}} = 0.18 \dots 0.36 \quad (11)$$

gdje su T_{63} i T_{95} vremenski periodi nakon kojega odziv na step pobudu poprimi vrijednost od 63% i 95% od vrijednosti ustaljenog stanja.

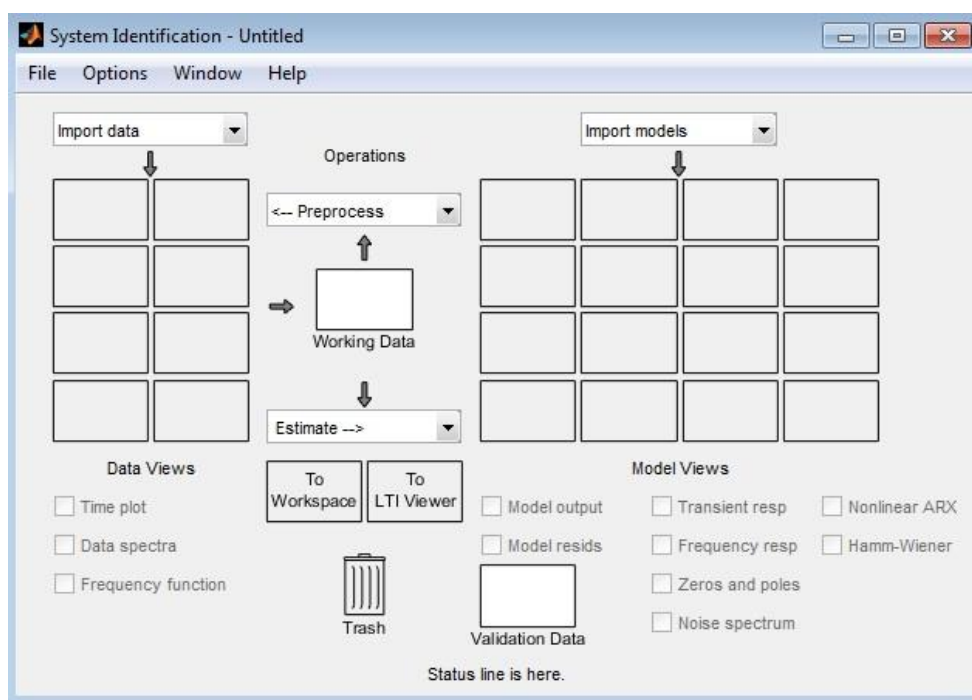
Reuter je 1995. ponudio optimalno vrijeme uzorkovanja za hidrauličke servo-sustave između 0.86 i 1.3 ms kao rezultat analize entropije. Stoga, za hidrauličke servo-sustave, vrijeme uzorkovanja bi trebalo biti između 1-2 ms, što je uobičajena praksa danas. Međutim, prava vrijednost vremena uzorkovanja ovisi o veličini i dinamici hidrauličkog sustava kojega imamo.

U ovom slučaju vrijeme uzorkovanja $T_s = 0.01$ s (10 ms).

3.5. Prikupljanje ulazno-izlaznih podataka

Za prikupljanje ulazno-izlaznih podataka koristi se programski paket MATLAB sa svojim dodatnim programima i alatima. Pomoću ovoga software-a generiraju se pobudni signali, i nakon spajanja na eksperimentalni sustav, snimaju se odzivi te se dobiju neophodni ulazno-izlazni podaci za identifikaciju procesa.

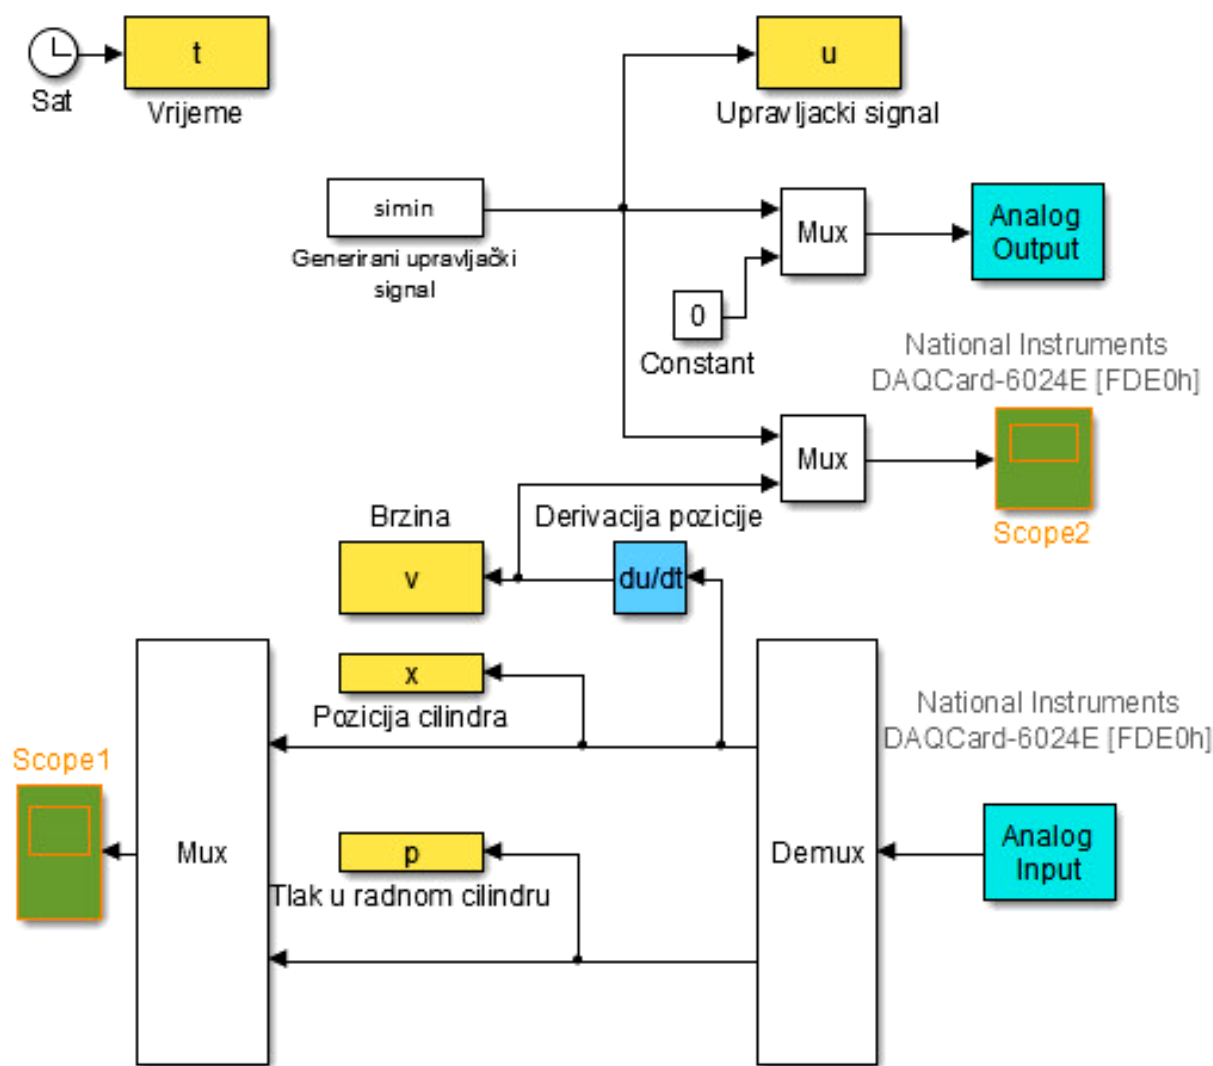
System Identification Toolbox je alat u programskom paketu MATLAB koji nam pruža mogućnost da dobijemo linearne i nelinearne matematičke modele sustava pomoću mjerenih ulazno-izlaznih podataka. System Identification Toolbox sadrži Matlab-ove funkcije, blokove iz Simulinka i aplikacije za konstruiranje matematičkih modela dinamičkih sustava. Dopusća nam korištenje i kreiranje modela sustava koji se teško mogu modelirati. Mogu se koristiti ulazno-izlazni podaci vremenske i frekvencijske domene za identifikaciju kontinuiranih i diskretnih prijenosnih funkcija, modela procesa i modela prostora stanja. Ovaj alat nam pruža i mnoge algoritme za estimaciju parametara.



Slika 21. Grafičko sučelje System Identification Toolbox-a

Vrlo jednostavnim korištenjem možemo unijeti ulazne i izlazne podatke o sustavu koji su neophodni za daljni proces identifikacije.

Ulazni upravljački signal za elektrohidraulički sustav je napon na razvodniku. Razvodnik može primiti ulazni napon od -10 V do +10 V. Ako na razvodnik pošaljemo više od +10 V ili manje od -10 V, zbog limita analognog izlaza akvizicijske kartice, izlazni napon će se zadržati u rasponu ± 10 V, tako da ne možemo preopteretiti sustav s ulaznim signalom i nikakva havarija ili kvar se ne može dogoditi zbog prekoračenja. Na eksperimentalni elektrohidraulički postav je preko akvizicijske kartice povezano računalo s Matlab programskim software-om i preko alata Simulink upravljamo s istim. Na sljedećoj slici (*Slika 22.*) je prikazan tijek signala:




Slika 22. Blokovski dijagram prikupljanja podataka

Signal *simin* je generirani ulazni signal tipa PRMS (pseudo random multilevel signal) koji je konstruiran na osnovi prethodnih poglavlja i preporuka i njega spremamo u varijablu *u*. Taj generirani signal *u* se šalje na ulaz razvodnika koji upravlja elektrohidrauličkim sustavom koji

je u ovom slučaju u otvorenom upravljačkom krugu. Dakle ulaz u sustav je generirani signal u , a izlaz iz sustava je pozicija hidrauličkog cilindra x koju dobijemo kao izlazni signal ugrađenog linearnog enkodera. Derivacijom pozicije cilindra po vremenu dobijemo brzinu cilindra v .

3.5.1. Pseudo-random multi-level signal – PRMS


Kako bi se postigle kvalitetne značajke modela, biranje vremena zadržavanja razine amplitude kod PRMS signala se određuje kompromisom između utjecaja na sustav i informacije o dinamici sustava. Slika 23. pokazuje ulazni upravljački signal i odziv elektrohidrauličkog sustava na takvu pobudu.



Slika 23. Odziv sustava na PRMS signal (veća frekvencija)

Kako se deriviranjem unosi šum u signal, a brzina v se dobije derivacijom pozicije cilindra, dobije se signal brzine opterećen šumom. Frekvencija ulaznog upravljačkog signala je 1 Hz. Poslije ovoga signala na eksperimentalni postav primjenjen je signal sa duplo manjom

frekvencijom od 0.5 Hz kako bi se otkrilo pokazuje li sustav veliko odstupanje od prvog pokušaja i odziv sustava je izgledao ovako:




Slika 24. Odziv sustava na PRMS signal (manja frekvencija)

Kasnije u procesu estimacije parametara pokazalo se da su obje frekvencije ulaznog upravljačkog signala pokazale isto ponašanje i dobiven je skoro identičan model sustava.

3.5.2. *Pseudo-random binarni signal*

Pseudo-random binarni signal (PRBS) je signal koji sadrži samo dvije razine amplitude. Puno se koristi za identifikaciju linearnih sustava dok se za nelinearne sustave korištenjem takvog signala mogu izgubiti neke informacije o dinamici sustava. Zbog toga razloga se PRMS signal više koristi od njega u identifikaciji. Kakav odziv je pokazao sustav na pobudu PRBS signala možemo vidjeti na *Slici 25*.




Slika 25. Odziv sustava na PRBS signal

Na prethodnoj slici, kod korištenja pseudo-random binarnog signala, srednja vrijednost upravljačkog signala napona na razvodniku iznosi $u_{srednje} = -0.667$ V što je na 10 V približno nuli i za očekivati je da će se hidraulički cilindar gibati malo u jednu i malo u drugu stranu i na kraju ostati na poziciji od početka gibanja uz mali pomak u lijevu stranu (na slici na niži položaj – negdje oko 200 mm), ali je cilindar završio na skroz drugom kraju uz pomak od 250 mm na lijevu stranu. Razlog se vjerojatno nalazi u različitim iznosima područja mrtve zone za vrijednosti signala oko nule, te nejednakim iznosima površina cilindra na strani klipa i klipnjače.

3.5.3. Chirp signal

Sljedeći signal kojim se pobuđuje elektrohidraulički sustav je sinusoidalni chirp signal. Chirp signal pokriva cijeli dio spektra frekvencija kojega postavimo i sve razine amplitude upravljačkog signala. Na taj način možemo biti sigurni da nećemo izostaviti niti jedan dio

frekvencija ili amplitude koji nas zanima. Na početku signala postavimo određenu početnu frekvenciju, a na kraju odredimo frekvenciju kojom signal završava. Nakon toga postavimo vrijeme koje je potrebno takvom signalu da dođe od početne do završne frekvencije.




Slika 26. Odziv sustava na chirp signal

Prethodni signal počinje s frekvencijom od 0.1 Hz i završava frekvencijom od 2 Hz. Dakle frekvencija se poveća dvadeset puta od početka do kraja prijelazne pojave. Prijelaz frekvencije završi se nakon 10 sekundi, a proces snimanja odziva sustava traje 17 sekundi. U ovom slučaju također možemo vidjeti tendenciju cilindra da ide u lijevu stranu iako je srednja vrijednost upravljačkog signala $u_{srednje} = 0$ V.

3.5.4. Sinusoida s tri frekvencije

U ovom slučaju odabran je ulazni upravljački multi-sinusni signal s tri različite frekvencije. Ovaj multi-sinusni signal je prihvatljiviji od originalnog sinusnog signala zbog toga što je u mogućnosti uhvatiti karakterističnu dinamiku elektrohidrauličkog sustava. Signal je predstavljen jednadžbom 12 i prikazan na Slici 27.:


$$\text{multisin}(t) = \cos(0.5t_s) + \cos(2t_s) + \cos(5t_s) \quad (12)$$




Slika 27. Odziv sustava na sinusoidu s tri frekvencije

3.5.5. Tendencija gibanja hidrauličkog cilindra u lijevu stranu


Razlika u brzinama gibanja cilindra za jednaki iznos napona na razvodniku posljedica je nejednakosti površina na strani klipa i na strani klipnjače te zbog različitih iznosa područja mrtve zone za vrijednosti signala oko nule. Zbog toga hidraulički cilindar ima tendenciju gibanja prema lijevoj strani. Na *Slici 28.* i *Slici 29.* je prikazan odziv sustava na signal od +10 V i -10 V na razvodniku.






Slika 28. Odziv s +10 V na razvodniku

Nakon odziva sustava na +10 V na hidrauličkom razvodniku možemo vidjeti razliku u odzivu sustava s -10 V na hidrauličkom razvodniku.




Slika 29. Odziv s -10 V na razvodniku

Nakon svih signala koji su primjenjeni na ulaz razvodnika kao upravljački signal prikupljeni su svi potrebni podaci za proces identifikacije modela elektrohidrauličkog sustava. Ulazni signal je napon na razvodniku u , a kao izlaz iz procesa može se uzeti pozicija hidrauličkog cilindra x ili derivaciju pozicije čime dobijemo brzinu cilindra v . Kako signal brzine sadrži šum u sebi mora se filtrirati. Za filtraciju se koristi Butterworthov niskopropusni filter koji ima maksimalno ravnu amplitudno frekvencijsku karakteristiku u području propuštanja.



Slika 30. Butterworthov filter signala brzine

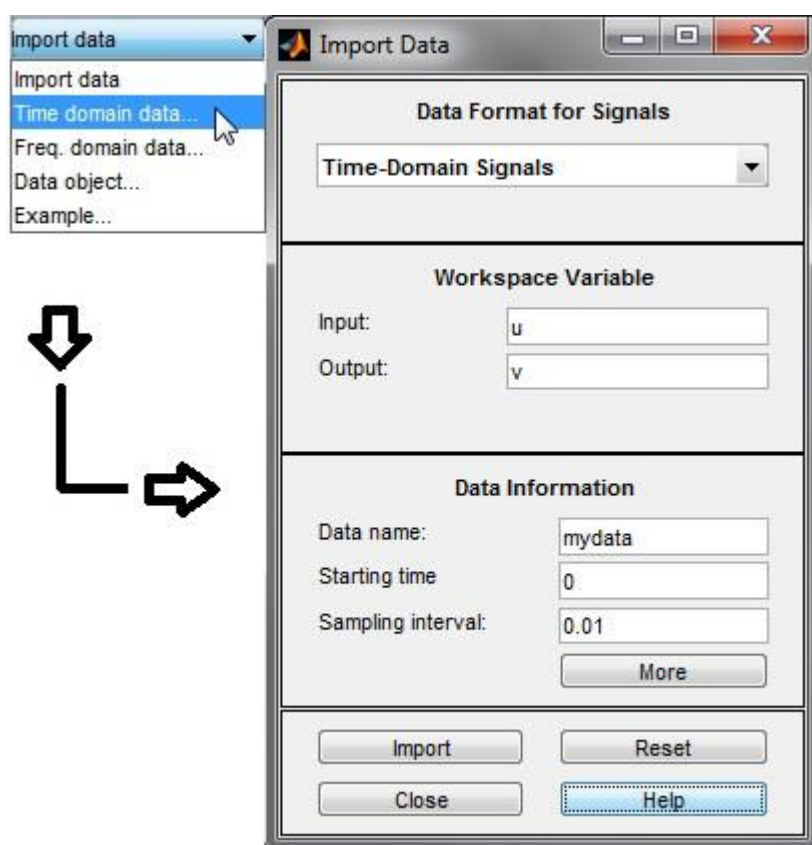


Slika 31. Filtar brzine

Filtar je primjenjen pomoću Matlab-ove funkcije *butter* koja konstruira analogni filter koji filtrira signal brzine v . Na slikama (Slika 30. i Slika 31.) može se vidjeti kako filtrirani signal nema uopće izraženoga šuma kao signal koji nije filtriran, ali zbog toga na filtriranom signalu postoji malo kašnjenje koje unosi filter brzine što se može poboljšati korištenjem funkcije *filtfilt* koja ne unosi kašnjenje u signal.


3.6. Estimacija i validacija procesa – System Identification Toolbox

Nakon prikupljenih svih podataka ulaza i izlaza sustava za unaprijed određene radne uvjete ti podaci se učitavaju u Matlab. Utipkavanjem naredbe *ident* otvara se identifikacijski alat u kojem se izvodi proces identifikacije. Možemo učitati podatke sa jednim ulazom i jednim izlazom (SISO) iz obične datoteke u System identification Toolbox aplikaciju iz Matlab-ovog 'workspace'-a. Učitavanje podataka u Matlab radimo pomoću grafičkog sučelja na sljedeći način:



Slika 32. Unos podataka u System Identification Toolbox

Nakon unošenja podataka koji predstavljaju naš sustav može se estimirati model koji bi odgovarao razmatranom sustavu. Odabiranjem polinomskih modela pojavi se prozor u kojemu možemo podešavati red brojnika i nazivnika modela, kašnjenje i druge stvari što možemo vidjeti na sljedećoj slici (Slika 33.):




Slika 33. Odabir željene metode estimacije

Matematički model sustava može se prikazati u obliku:

- diferencijalnih jednadžbi
- prikaz u prostoru stanja
- prijenosnih funkcija
- prijenosnih matrica

Na temelju združenih skupova podataka ili mjernih rezultata vremenskih tijekova ulaznih i izlaznih signala dinamičkog procesa traži se struktura i parametri odgovarajućeg matematičkog modela. Poslije otvaranja polinomskih modela i modela prostora stanja postoje opcije odabira načina estimacije parametara u *ident* prozoru.



Slika 34. Opcije odabira načina estimacije

Interpretacija informacije strukture modela ovisi o prethodnom odabiru u pop-up izborniku.

Ovo pokriva šest odabira:


- ARX model (engl. ARX – Autoregressive exogenous)
- ARMAX model (engl. ARMAX – Autoregressive-moving average exogenous)
- OE model (engl. OE – Output-Error)
- BJ model (engl. BJ – Box-Jenkins)
- Model prostora stanja
- Model strukture definiran inicijalnim modelom (korisnički definirana struktura)

Najvažniji postupci procjene (estimacije) parametara:

- Metoda najmanjih kvadrata – LS (“Least Squares”- metoda);
- Poopćena metoda najmanjih kvadrata – GLS
- Metoda pomoćnih varijabli – IV (“Instrumental Variable” - metoda)
- Metoda maksimalne sličnosti – ML (“Maximum-Likelihood” - metoda)

ARX struktura modela


U ARX strukturi se koriste A i B polinomi:



Slika 35. Blokovska shema ARX modela [6]

ARMAX struktura modela


U ARMAX strukturi se koriste A , B i C polinomi:



Slika 36. Blokovska shema ARMAX modela [6]

OE struktura modela


U OE strukturi se koriste B i F polinomi:



Slika 37. Blokovska shema OE modela [6]

BJ struktura modela

U BJ strukturi se koriste B , F , C i D polinomi:




Slika 38. Blokovska shema BJ modela [6]

Zbog dobivanja odgovarajućeg modela važnu ulogu predstavlja karakter ulaznog signala kojim se pobuđuje razmatrani sustav. Ulazni signal mora biti takav da osigura izlazni signal koji sadrži potrebne informacije o procesu. On se dovodi u obliku napona s upravljačkog računala preko D/A pretvornika akvizicijske kartice na proporcionalni ventil, a izlaz procesa je pozicija klipa cilindra izražena kao napon mjereno linearnim enkoderom. Identifikacija se provodi *offline* postupkom jer smo prethodno snimili podatke ulaza i izlaza na eksperimentalnom postavu. Ukupno je snimljeno 3000 ulaznih i 3000 pripadajućih izlaznih veličina za vrijeme trajanja eksperimenta $T_{exp} = 30$ s i s vremenom uzorkovanja $T_s = 10$ ms. Prva polovica snimljenih podataka koristi se za estimaciju procesa tj. konstruiranje matematičkog modela, a druga polovica za validaciju procesa tj. za provjeru valjanosti prethodno konstruiranog modela.

3.6.1. Estimacija parametara i validacija – PRMS signal

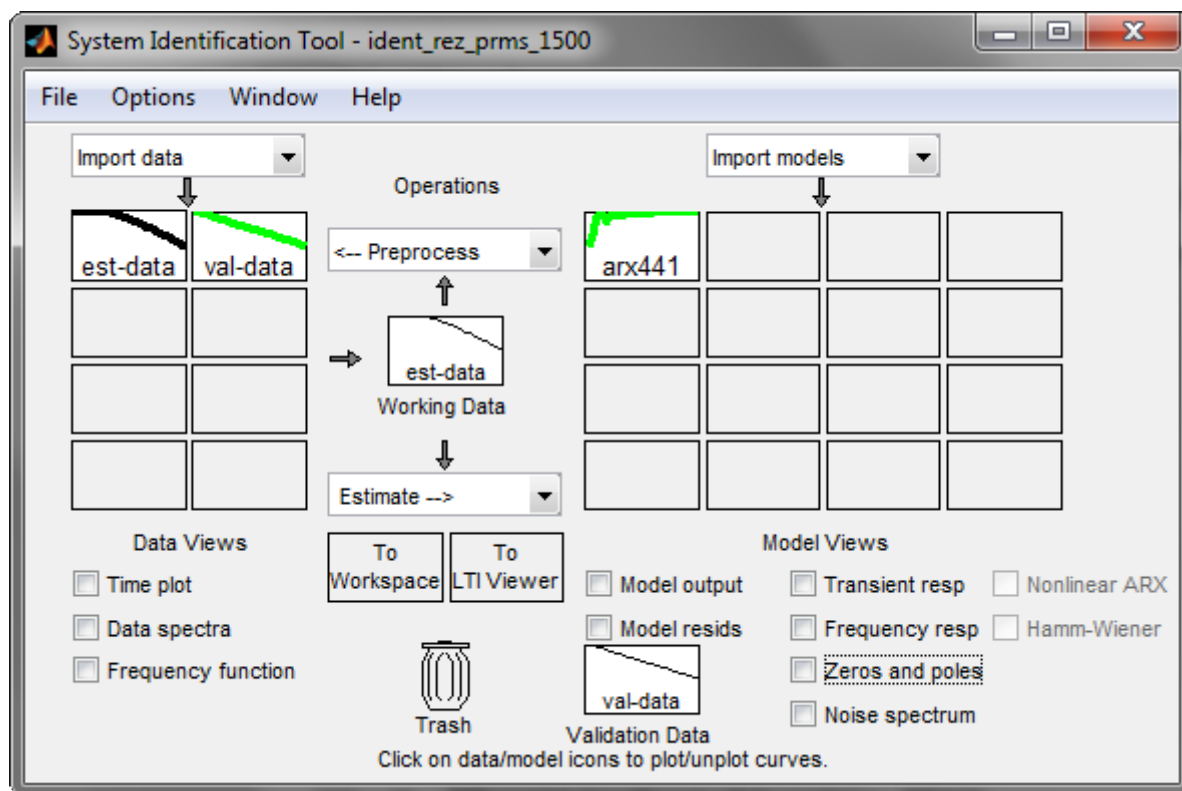
Procjena (estimacija) parametara elektrohidrauličkog sustava s jednim ulazom i jednim izlazom provest će se metodom najmanjih kvadrata – LS i strukturom modela ARX četvrtoga reda kako je prikazano na *Slici 33*. U prikazanom prozoru na slici namjestimo sve što je potrebno i pritiskom na tipku *Estimate* konstruiramo model od prikupljenih ulazno-izlaznih signala.

Ulazno-izlazni podaci




Slika 39. Ulazno-izlazni podaci PRMS signala za estimaciju - pozicija

Na prethodnoj slici (Slika 39.) prikazana je prva polovica ulazno-izlaznih veličina (1500 točaka) PRMS signala, potrebnih za estimaciju procesa. Tu polovicu podataka unosimo u *Import data* polje kako je prikazano na Slici 32. i klikom miša prenesemo u *Working data* polje. Nakon toga estimiramo model kako je prikazano na Slici 33., a drugu polovicu podataka prenesemo u *Validation data* polje. Na sljedećoj slici prikazan je primjer:




Slika 40. System Identification Toolbox – raspored podataka

Na sljedećoj slici (Slika 41.) prikazana je druga polovica snimljenih izlaznih veličina (1500 točaka) koja služi za validaciju procesa i predstavlja mjereni odziv sustava i izlaz konstruiranog modela koji predstavlja simulaciju odziva.




Slika 41. Mjereni i simulirani odziv sustava - PRMS (pozicija)



Slika 42. Polovi i nule – PRMS

Svi polovi prethodnog modela su unutar jedinične kružnice u Z ravnini što znači da je modelirani sustav stabilan, a kako ima dvije nule izvan kružnice govori nam da će odziv imati podbačaj na početku. Nule sustava ne utječu na stabilnost sustava.



Slika 43. Autokorelacijska i kroskorelacijska funkcija – PRMS

Model je zadovoljavajući ako su autokorelacijska i kroskorelacijska funkcija uglavnom unutar

označenih granica. Kada smo zadovoljni dobivenim rezultatima i želimo primjeniti konstruirani model u određenim okolnostima moramo mišem povući estimirani model na *To Workspace* polje ili dvostrukim klikom na model dobiti detaljne informacije o modelu.

Diskretni ARX model sa prethodnih slika (*Slika 40.*), konstruiran na osnovi PRMS signala, prikazuje se sljedećim izrazom 13:

$$A(z)y(t) = B(z)u(t) + e(t) \quad (13)$$

$$A(z) = 1 - 1.096z^{-1} - 0.3448z^{-2} + 0.0791z^{-3} + 0.362z^{-4} \quad (14)$$

$$B(z) = 0.0007884z^{-1} + 0.001161z^{-2} - 0.000411z^{-3} - 0.0013z^{-4} \quad (15)$$

Naredbama:

```
[a,b]=th2poly(arx441)
sys=tf(b,a, 0.01)
```

u MATLAB-u, dobiju se polinomi A i B , ARX modela dinamike sustava sa *Slike 35.* i potom naredbom *tf()*, prethodno konstruirani polinomi predstavljaju diskretnu prijenosnu funkciju u z domeni (izraz 16). Ta konstruirana diskretna prijenosna funkcija predstavlja diskretni ARX model dinamike sustava. Kako je model konstruiran na osnovi PRMS signala i pozicije cilindra kao izlaza kod estimacije parametara, izlaz ove diskretne prijenosne funkcije također je pozicija cilindra. Rezultati pomnoženi s faktorom 30 predstavljaju poziciju cilindra u milimetrima (mm).

Diskretna prijenosna funkcija:

$$G(z) = \frac{0.0007884 z^3 + 0.001161 z^2 - 0.000411 z - 0.0013}{z^4 - 1.096 z^3 - 0.3448 z^2 + 0.0791 z + 0.362} \quad (16)$$

Naredba *d2c()*:


```
sys_cont=d2c(sys)
```

prebacuje diskretnu prijenosnu funkciju u kontinuiranu što se vidi u izrazu 17:

$$G(s) = \frac{0.1793 s^3 - 25.13s^2 + 10190s + 62390}{s^4 + 101.6s^3 + 57680s^2 + 263000s + 8570} \quad (17)$$


Nakon estimacije parametara pomoću pozicije kao izlaznog signala, sada će se prikazati estimacija parametara modela pomoću deriviranog signala pozicije cilindra, čime se dobije

brzina hidrauličkog cilindra. Zbog deriviranja se unosi šum u signal brzine, ali se također filtrira da bi se dobio signal bez šuma. Prikazati će se i estimacija s originalnim i filtriranim signalom.



Slika 44. Ulazno-izlazni podaci PRMS signala za estimaciju - brzina


Koliko dobro obadva estimirana modela oponašaju sustav možemo vidjeti na sljedećoj slici:



Slika 45. Mjereni i simulirani odziv sustava - PRMS (brzina)

Estimirani model pomoću signala brzine je znatno brži na step pobudu od modela estimiranog pomoću signala pozicije cilindra.

Na Slici 46. je prikazana razlika odziva filtriranog i originalnog signala brzine na step pobudu.




Slika 46. Odziv na step funkciju – PRMS

3.6.2. Estimacija parametara i validacija – Chirp signal


Sljedeći proces identifikacije sustava tj. estimacije parametara i validacije provesti će se na osnovu ulazno-izlaznih podataka sustava pobuđenog chirp signalom. Kako bi se dobio bolji uvid u dinamiku sustava chirp signal mijenja kontinuirano vlastitu amplitudu, kao sinusoida, i vlastitu frekvenciju.

Ulazno-izlazni podaci




Slika 47. Ulazno-izlazni podaci chirp signala za estimaciju

Na prethodnoj slici (Slika 47.) prikazan je prvi dio ulazno-izlaznih veličina (1000 točaka) chirp signala, potrebnih za estimaciju procesa. Kako je za dobru estimaciju potrebno imati prihvatljiv signal da se dobro 'uhvati' dinamika procesa, chirp signal mijenja svoju amplitudu od -10 V do +10 V te vlastitu frekvenciju od 0.1 Hz do 2 Hz unutar 10 sekundi trajanja eksperimenta. Isti taj dio ulazno-izlaznih veličina koristi se za validaciju procesa jer eksperiment traje samo 10 sekundi. Simulirani odziv modela može se vidjeti na sljedećoj slici:




Slika 48. Mjereni i simulirani odziv sustava – Chirp signal



Slika 49. Polovi i nule – Chirp signal (plavo – 3. red, crveno – 2. red sustava)

Na slici polova i nula konstruiranog ARX modela trećeg reda može se vidjeti poklapanje jednog pola i jedne nule što, prema [12], znači da se može smanjiti red modela na model drugog reda.

Uspoređivanjem oba modela ustanovilo se da su odzivi (*Slika 48.*) i frekvencijske karakteristike (*Slika 50.*) sustava veoma slične i da se opravdano može smanjiti red sustava.




Slika 50. Frekvencijski odziv

Odziv simuliranoga ARX modela trećeg reda podudara se 90.2%, a odziv ARX modela drugog reda podudara se 89.71% s mjerenim odzivom. Razlika u odzivu na step pobudu se jedva može primjetiti.

Modeli Output Error i Box-Jenkins na pobudni chirp signal dali su jednako dobar odziv što se tiče podudaranja s mjerenim odzivom, ali nešto sporiji odziv na step funkciju. Chirp signal je jednostavniji od PRMS-a i konstruirani modeli se bolje podudaraju s mjerenim odzivom.


3.6.3. Estimacija parametara i validacija – Sinusoida s tri frekvencije

Ulazno-izlazni podaci




Slika 51. Ulazno-izlazni podaci sinusoide s tri frekvencije za estimaciju

Na Slici 51. prikazan je signal sinusoide s tri frekvencije. Pomoću njega se pokušava dobiti kompletnija slika dinamike sustava zbog različitih frekvencija i amplituda. Na sljedećoj slici (Slika 52.) mogu se vidjeti rezultati estimacije. Estimirani model dobro prati drugi dio signala koji se koristi za validaciju procesa i zadovoljava potrebne uvjete.



Slika 52. Mjereni i simulirani odziv sustava - Sinusoida s tri frekvencije




Slika 53. Polovi i nule - Sinusoida s tri frekvencije

Model je trećega reda i poklapaju mu se jedan pol i jedna nula, ali skraćivanjem reda sustava model ne prati dovoljno dobro i povećava mu se vrijeme odziva. Model je konstruiran metodom ARX jer ostale metode ne daju dovoljno dobra rješenja.

3.6.4. Usporedba modela

Poslije estimacije modela pomoću svih primjenjenih signala na ulaz hidrauličkog razvodnika i snimanja odziva elektrohidrauličkog sustava može se usporediti svaki dobiveni model za svaki režim rada sustava. Tako se može odrediti koji model najvjerođostojnije opisuje ponašanje eksperimentalnog postava. Ulazno-izlazni signali su već poznati pa će se prikazati samo odzivi svih modela na sve pobudne signale i usporediti s mjerenim stanjem tj. provest će se validacija svih modela na osnovi svih signala.


Validacija modela na osnovi validacijske funkcije - sinusoide s tri frekvencije



Slika 54. Usporedba modela na osnovi estimacije pomoću sinusoide s tri frekvencije

Najveći postotak preklapanja mjerenog i simuliranog signala predstavljenih modela na pobudu sinusoide s tri frekvencije ima signal modela koji je konstruiran upravo na osnovu toga signala. Iza njega slijedi model konstruiran na osnovu PRMS signala, a nakon njega slijede i modeli na osnovu PRBS i chirp signala kako je prikazano na *Slici 54*. Na sljedećim slikama također je prikazano i stanje na ostale pobudne signale.


Validacija modela na osnovi validacijske funkcije - PRMS signala



Slika 55. Usporedba modela na osnovi estimacije pomoću PRMS signala


Na prethodne dvije slike prikazane su validacijske funkcije i odzivi svih odgovarajućih modela na te validacijske funkcije. To pokazuje da dobiveni model dinamike sustava prati dobro i ostale tipove signala, bez obzira što je konstruiran na osnovi jednog tipa signala. Tako npr. ARX model konstruiran pomoću PRBS signala, prati dobro i sinusoidalnu i PRMS pobudu što se vidi iz preklapanja s izmjerenim odzivom ispod slika, i to 61,37% i 68,15%.

Validacija modela na osnovi PRBS signala



Slika 56. Usporedba modela na osnovi estimacije pomoću PRBS signala

Validacija modela na osnovi chirp signala



Slika 57. Usporedba modela na osnovi estimacije pomoću chirp signala

Na prethodnim slikama može se vidjeti kako se ponašaju estimirani modeli na određene vrste pobudnih signala. Ako se gledaju brojeke koje nam daju informaciju o preklapanju odziva modela u usporedbi sa stvarnim mjerenim odzivom, može se vidjeti da neki modeli imaju zaista


zadovoljavajuće odzive, kao npr. Box-Jenkins 22221 model konstruiran na osnovi chirp pobudnog signala. Svi modeli vjerodostojno prate mjereni odziv sustava, ali se također osjeti nelinearnost sustava u identifikaciji i tendencija gibanja hidrauličkog cilindra prema lijevoj strani.

Modeli dinamike sustava:

U procesu identifikacije i estimacije parametara razmatrani su brojni modeli dinamike sustava. Odabir modela određivao se prema:

- karakteru identifikacijskog signala (PRMS, PRBS, chirp i sinusoida s tri frekvencije)
- metodi estimacije (ARX, OE i BJ)

Prvo su odabrani karakter identifikacijskog signala, u ovom slučaju pseudo-random multilevel signal i metoda estimacije parametara modela ARX pa se došlo do prvog modela dinamike sustava. Nakon toga su isprobane i preostale dvije metode OE i BJ i preostale kombinacije reda modela. Isti postupak je ponovljen i za ostale karaktere identifikacijskog signala i ostale metode estimacije parametara modela dinamike sustava. Najčešće ARX modeli daju najbolje rješenje i najviše su korišteni u zadatku, dok modeli dobiveni pomoću OE metode imaju dobro preklapanje, ali im autokorelacijska funkcija pogreške predikcije ne bude u području od 95% pouzdanosti, što se vidi na sljedećoj slici (Slika 58.).



Slika 58. OE model dinamike sustava

Zbog problema sa prethodne slike OE modeli se nisu uzimali u obzir kod analize najprihvatljivijih modela.

Nakon razmatranja odabranih modela pristupa se procesu validacije i odabiru odgovarajućih i najprihvatljivijih modela. Estimacija parametara provodi se od prve polovice točaka signala, a proces validacije na osnovi druge polovice točaka istog signala. Ako dobiveni model zadovolji validaciju na osnovi funkcije istoga karaktera kao i kod estimacije, onda se za isti model provodi i validacija na osnovi validacijskih funkcija drugoga karaktera. To se može vidjeti na slikama *Slika 54.*, *Slika 55.*, *Slika 56.* i *Slika 57.* Modeli koji su prikazani na prethodnim slikama su odabrani jer su se u postotcima najviše poklapali s izmjerenim odzivom, što se može vidjeti direktno ispod slika. Prema analizama preko validacijskih funkcija (PRMS, PRBS, chirp i sinusoida s tri frekvencije) sa prethodne četiri slike, najprihvatljiviji odabir je BJ 22221 model konstruiran na osnovi chirp signala, koji ima najvišu stopu preklapanja i najvjernije prati izmjereni signal.


4. SIMULACIJA PROCESA

Simulacija procesa se koristi za konstruiranje, razvoj, analizu i optimizaciju tehničkih procesa. Bazirana je na reprezentaciji kemijskih, fizičkih, bioloških i drugih tehničkih procesa pomoću modela u programskom okruženju. Za simulaciju elektrohidrauličkog sustava pomoću dobivenog modela iz prethodnog poglavlja koristi se programski alat *Matlab/Simulink*. Za provjeru vjerodostojnosti modela na eksperimentalnom sustavu prvo će se na računalu konstruirati simulink model u kojemu će prethodno estimirani model predstavljati eksperimentalni postav. Cilj simulacije je projektiranje regulatora za pozicioniranje hidrauličkog cilindra.

4.1. Podešavanje parametara regulatora

Da bi se izbjegao neplanski pristup pokusnom namještanju parametara regulatora u procesnoj regulaciji, što u pogonskim uvjetima nije poželjno, razrađene su jednostavne metode koje se temelje na teorijskim analizama i praktičkim ispitivanjima.

Prvi korak je eksperiment u otvorenom krugu koji služi za snimanje prijelazne karakteristike procesa.



Slika 59. Odziv procesa na skokovitu pobudu - eksperiment u otvorenom krugu [10]

Tri parametra se moraju očitati sa prijelazne karakteristike, a to su:

- statičko pojačanje procesa $K_P = \Delta y / \Delta u$,
- kašnjenje procesa τ ,
- nadomjesna vremenska konstanta procesa T_P

Na temelju ta tri parametra proračunava se konstanta:

$$a = \mu K_P; \text{ gdje je } \mu = \frac{\tau}{T_P} \quad (18)$$

Metoda ugađanja parametara je Takahashijeva metoda. Ona predstavlja modifikaciju Ziegler-Nicholsova postupka.

Na temelju rezultata eksperimenta u zatvorenom krugu i dobivenih podataka K_u , T_u preporuke za izbor parametara dane su u tabeli:


Regulator	Takahashijeve preporuke B		
	K	K_i	K_d
P	$0.5K_u$.	.
PI	$0.45K_u - 0.5K_i$	$0.54 \frac{K_u T}{T_u}$.
Kada $\tau \approx 0.25T$ umanjiti ove iznose			
PID_{par}	$0.6K_u - 0.5K_i$	$1.2 \frac{K_u T}{T_u}$	$\frac{3}{40} \frac{K_u T}{T_u}$
Kada $T \approx 4\tau$ ne preporučuje se			

Tablica 1. Takahashijeve preporuke [10]

Na temelju rezultata simulacije u zatvorenom krugu (Slika 60.) za dobivenu diskretnu prijenosnu funkciju (16) iz prethodnog poglavlja dobiveni su sljedeći rezultati:

$$K_u = 720; T_u = 0.04s \quad (19)$$

K_u – kritično pojačanje, T_u – peroid oscilacija

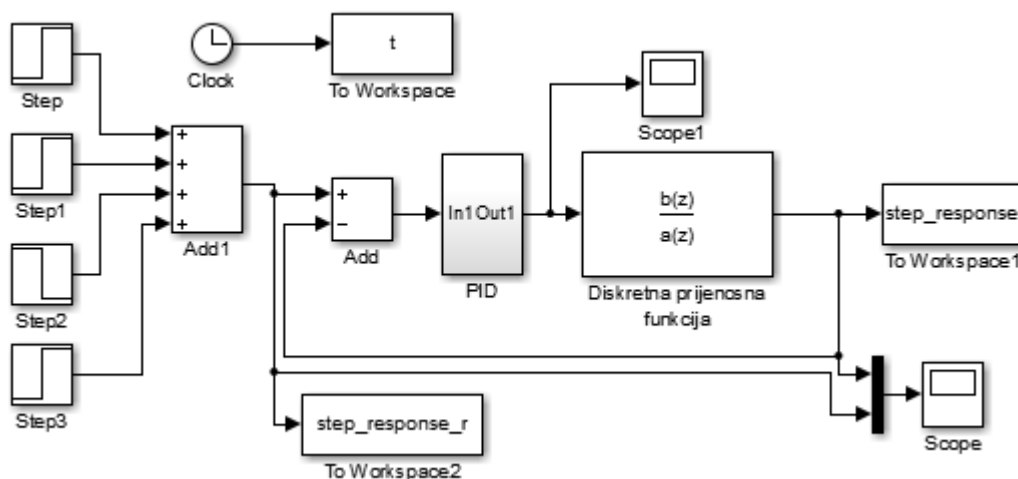


Slika 60. Određivanje kritičnog pojačanja regulatora

4.2. Simulacija procesa


Zbog svojih prednosti i svoje jednostavnosti PID regulator ima jako široku primjenu i danas, unatoč brojnim drugim prisutnim regulatorima. Zbog toga se izabere kao prva opcija za regulaciju elektrohidrauličkog sustava. Parametri PID regulatora su izračunati pomoću Takahashijevih preporuka iz *Tablice 1.* i jednaki su kako slijedi:

$$K_P = 324; K_I = 216; K_D = 13.5 \quad (20)$$




Slika 61. Regulacijski krug – simulacija

Diskretna prijenosna funkcija (16) u simulaciji je estimirani $arx441$ model na osnovi PRMS pobudnog signala.




Slika 62. Podsustav PID

Kako se pristupa regulaciji sustava bez njegovog prethodnog poznavanja, pretpostavilo se da će PID regulator biti zadovoljavajuće rješenje za razmatrani sustav. Međutim, nakon prve simulacije, rezultati su pokazali neprihvatljivo nadvišenje u odzivu (*Slika 63.*) sustava. *I* djelovanje regulatora eliminira regulacijsku pogrešku i ubrzava odziv, ali isto tako pridonosi povećanju nadvišenja i vremena smirivanja. Kako je nadvišenje bilo preveliko ono se kompenziralo jednostavnim odspajanjem *I* djelovanja regulatora. Nepoželjno nadvišenje kao i njegova kompenzacija mogu se vidjeti na sljedeće dvije slike:



Slika 63. Odziv regulacijskog kruga na referentni signal – PID regulator

Kod sljedećeg regulatora *I* djelovanje nije spojeno što se vidi na *Slici 62.* pa djeluje samo PD regulator za poziciju. Elektrohidraulički sustav ima ograničenje protoka kojeg može dati crpka na $Q = 4 \text{ l/min}$, a također i hidraulički razvodnik ima ograničenje od $\pm 10 \text{ V}$ na svom ulazu i ne može odgovarati na prevelike zahtjeve procesa pa je zato dodan i blok saturacije signala prije ulaza u model da bi se prikazalo realno stanje. Bez saturacije signal napona bi kratkovremeno postigao ogromnu veličinu i kompenzirao grešku i odziv sustava bi bio puno brži tj. nemoguć za eksperimentalni postav.

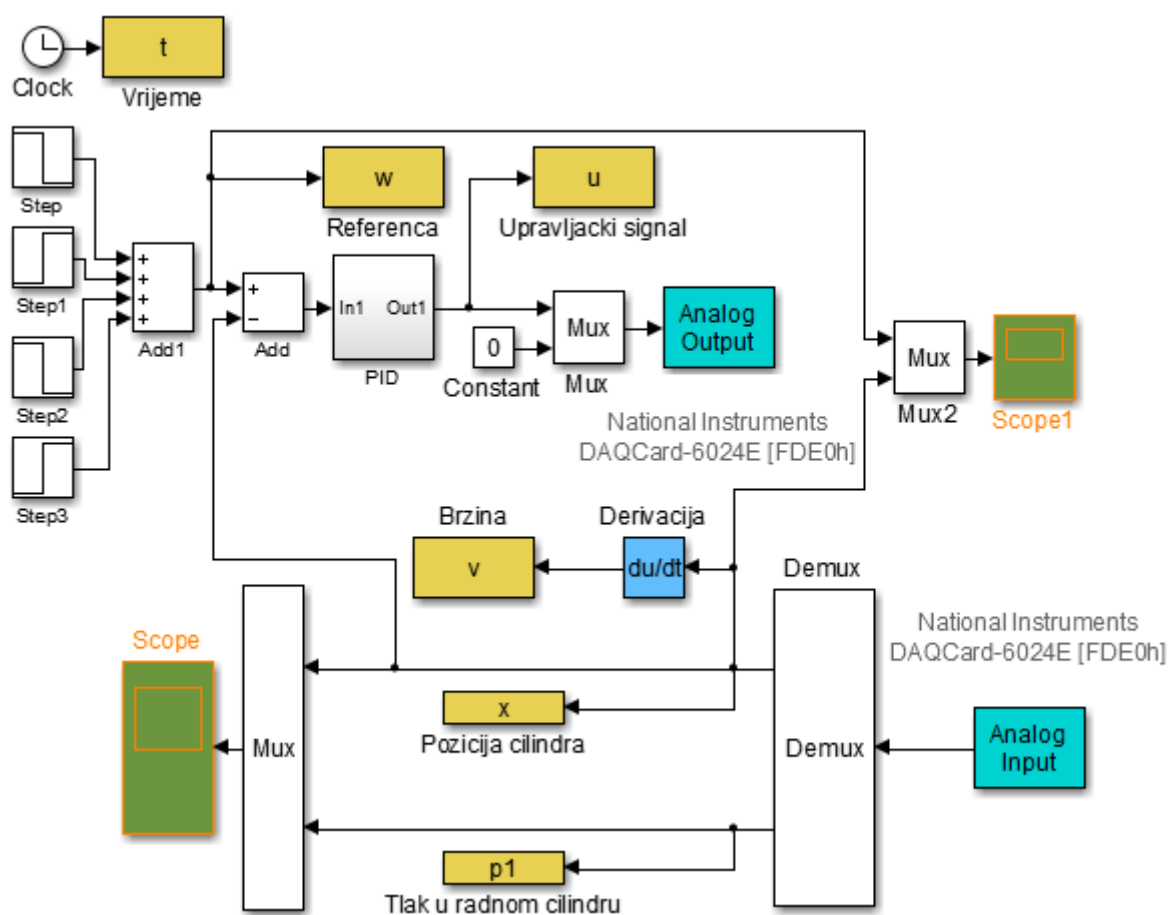


Slika 64. Odziv regulacijskog kruga na referentni signal – PD regulator

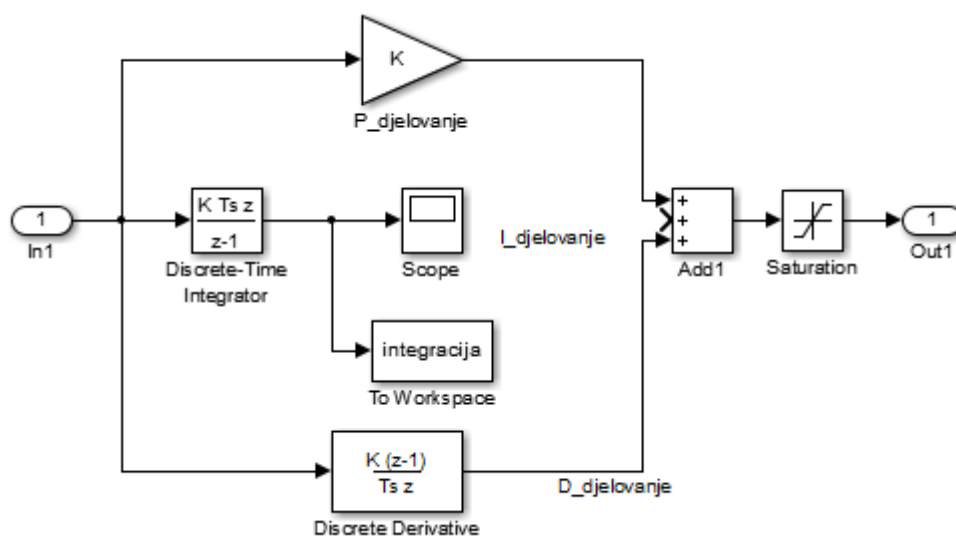
5. EKSPERIMENTALNI REZULTATI

Cijeli proces identifikacije i simulacije sustava pripremljen je za eksperimentalnu primjenu na elektrohidrauličkom sustavu. Uobičajena pojava je da ponekad nije poželjno eksperimentirati na pravom eksperimentalnom postavu zbog različitih razloga kao što su sigurnost, nepristupačnost, itd. pa nam je potrebna mogućnost računalne simulacije. Analiza tehničkih sustava je znatno olakšana kada imamo simulacijski model i eksperimentiramo na računalu. Kada provedemo određenu simulaciju i zadovoljni smo njezinim rezultatima, tada prelazimo na pravi eksperiment jer rezultati simulacije nikad nisu dovoljno sigurni bez eksperimenta koji je stvarna provjera obavljenog posla.

Eksperimentalni elektrohidraulički sustav je preko akvizicijske kartice povezan na računalu kojim upravljamo procesom što se vidi na *Slici 65*.




Slika 65. Eksperimentalni regulacijski krug



Slika 66. Podsustav PD regulatora eksperimentalnog regulacijskog kruga


Nakon implementiranja predstavljenog regulatora pozicije hidrauličkog cilindra na eksperimentalni elektrohidraulički sustav snimljeni su odzivi sustava. Na sljedećoj slici (*Slika 67.*) prikazani su dobiveni rezultati:



Slika 67. Eksperimentalni rezultati

Na eksperimentalni sustav je primjenjen isti referentni signal s malom razlikom. Naime, na simulaciji model kreće sa pozicije $x = 0$ mm, a na eksperimentalnom postavu cilindar kreće s pozicije $x = 150$ mm što ne prestavlja veliku razliku i ne utječe značajno na proces. Na prikazanim rezultatima odziva eksperimentalnog sustava na *Slici 67.* može se vidjeti kako narav

eksperimenta odgovara prethodnoj simulaciji. To se bolje može vidjeti na sljedećoj slici (*Slika 68.*) koja prikazuje usporedbu odziva simulacije i eksperimenta.



Slika 68. Usporedba simulacije i eksperimenta

Simulacija s estimiranim modelom pomoću identifikacije sustava je veoma dobro prikazala kako se sustav ponaša što nam potvrđuje i sam eksperiment. Usporedbom simulacije i eksperimenta (*Slika 68.*) može se vidjeti kako se rezultati poprilično dobro preklapaju i kako računalna simulacija pomoću estimiranog modela dinamike sustava dobro predstavlja izvedeni eksperiment.

6. ZAKLJUČAK

U identifikaciji sustava cilj je doći do matematičkog modela eksperimentalnog postava koji opisuje vremensko ponašanje sustava na osnovu njegovih ulazno-izlaznih podataka. Provedbom procesa identifikacije elektrohidrauličkog sustava, u *Matlabovom* alatu *System Identification Toolbox*, može se zaključiti da je moguće doći do vjerodostojnog modela na relativno brz način, ako se prethodno snimi ulazno-izlazna karakteristika sustava. Kao što se vidi iz prethodnih poglavlja i prikazanih rezultata, ponašanje konstruiranoga matematičkog modela u simulaciji potpuno vjerno slijedi mjereni odziv eksperimenta. To potvrđuje da estimirani model korektno predstavlja eksperimentalni sustav. Da bi se došlo do što boljeg reprezentacijskog modela potrebno je dobro poznavati promatrani sustav. Bitni faktori kod identifikacije su odabir dobrog pobudnog signala za estimaciju, da bi se prikazao odziv na širok spektar frekvencija i amplituda ulaznog signala, i odabir metode estimacije modela na osnovu ulazno-izlaznih podataka. Na ovom sustavu najbolje rezultate pokazao je model konstruiran Box-Jenkinsovom metodom na osnovi chirp pobudnog signala i mjerene pozicije kao izlaza sustava, dok ostali modeli uopće ne zaostaju puno za njim. Zbog prisutnosti šuma u signalu brzine i izrazitoj nelinearnosti, pokazali su lošije modele u odnosu na modele pozicije kao izlaza sustava. Tako estimirani model korišten je za sintezu regulatora i dobiveni su zadovoljavajući rezultati. Prednost ove metode identifikacije sustava je što nisu potrebna detaljna specijalistička znanja o procesu i dobivaju se jednostavniji matemtički modeli.

LITERATURA

- [1] Željko Šitum: *Pneumatski i hidraulički servosustavi*, Fakultet strojarstva i brodogradnje, Zagreb
- [2] Karl-Erik Rydberg: *Hydraulic servo systems*, Linköpings universitet
- [3] Joško Petrić, Željko Šitum, Mihael Cipek: *Pneumatika i hidraulika*, Fakultet strojarstva i brodogradnje, Zagreb
- [4] Radoslav Korbar: *Pneumatika i hidraulika*, Veleučilište u Karlovcu, 2007.
- [5] Petar Cuglin, *Diplomski rad*, Fakultet strojarstva i brodogradnje, 2009.
- [6] Nedjeljko Perić, Ivan Petrović: *Identifikacija procesa*, Fakultet elektrotehnike i računarstva, Zagreb, 2005.
- [7] Mohieddine Jelali, Andreas Kroll: *Hydraulic Servo-systems - Modeling, Identification and Control*, Springer, 2003.
- [8] Lennart Ljung: *System Identification Toolbox – For Use with MATLAB*, User's Guide, 1997.
- [9] Željko Šitum: *Regulacija pneumatskih servosustava primjenom neizrazitog regulatora*, Doktorska disertacija, Fakultet strojarstva i brodogradnje, Zagreb, 2001.
- [10] Z. Vukić, Lj. Kuljača: *Automatsko upravljanje – analiza linearnih sustava*, Kigen, 2005.
- [11] T. Šurina: *Automatska regulacija*, Školska knjiga, Zagreb, 1987.
- [12] T. S. Soderstrom, Petre G. Stoica: *System Identification*, Prentice Hall, 1989.

PRILOZI

I. CD-R disc